

Жебка Вікторія Вікторівна

д.т.н., проф. зав. кафедри Технологій цифрового розвитку
 Державний університет інформаційно-комунікаційних технологій, м. Київ
 ORCID 0000-0003-4051-1190
 v.zhebka@duikt.edu.ua

Читулян Вадим Олегович

Аспірант, старший викладач
 Державний університет інформаційно-комунікаційних технологій, Київ, Україна
 ORCID 0009-0001-8846-9094
 mag5187403@stud.duikt.edu.ua

МОДЕЛЬ НА ОСНОВІ ГАУСІВСЬКОЇ РЕГРЕСІЇ ДЛЯ ПРОГНОЗУВАННЯ ПРОДУКТИВНОСТІ КОРПОРАТИВНИХ ВЕБ-СИСТЕМ ЗА КОНФІГУРОВАНИХ УМОВ НАВАНТАЖЕННЯ

Анотація. У статті розглядається задача прогнозування продуктивності корпоративних веб-систем в умовах варіативних конфігурацій апаратного та програмного середовища. Досліджено проблему надмірної вартості повного перебору простору конфігурацій для визначення оптимальних параметрів розгортання. Запропоновано метод побудови сурогатної моделі на основі гаусівської процесової регресії (GPR), яка відображає функцію $f(x, l) \rightarrow (\mu, \sigma)$, де x – вектор конфігураційних параметрів системи (оперативна пам'ять, кількість ядер CPU, розмір пулу з'єднань, кількість робочих процесів), l – вектор характеристик навантаження (кількість віртуальних користувачів, співвідношення операцій читання/запис), μ – прогнозоване значення р95-затримки відповіді, σ – невизначеність прогнозу. На відміну від адитивних моделей впливу конфігурацій (зокрема, підходу P4), запропонована GPR-сурогатна модель апроксимує нелінійну поверхню відгуку у повному просторі конфігурацій і навантажень, надаючи разом із точковим прогнозом відкалібрований довірчий інтервал для кожної точки прогнозування. Проведено збір навчальних даних за планом Латинського гіперкубічного вибірки (420 точок), реалізовано повний ML-пайплайн із порівнянням трьох ядер GPR (RBF, Матерн 5/2, раціональна квадратична функція), а також базових моделей XGBoost, Random Forest та адитивної лінійної моделі. Найкращі результати забезпечило ядро Матерн 5/2: $R^2 = 0,9863$, MAE = 34,4 мс, покриття 95% довірчого інтервалу – 0,937. Аналіз сурогатної ефективності встановив, що для досягнення $R^2 \geq 0,90$ достатньо 75 реальних вимірювань замість 720 у повній сітці (скорочення обсягу вимірювань на 89,6%). Виконано SHAP-аналіз важливості ознак, що підтвердив домінуючу роль конструйованої ознаки «інтенсивність навантаження» над первинними конфігураційними параметрами. Реалізовано критерій активного навчання на основі предиктивної дисперсії GPR для цілеспрямованого поповнення навчальної вибірки.

Ключові слова: гаусівська процесова регресія; сурогатна модель; прогнозування продуктивності; корпоративні веб-системи; кількісна оцінка невизначеності; латинський гіперкубічний план; SHAP-аналіз; активне навчання; виявлення аномалій навантаження; кібербезпека інфраструктури.

Zhebka Viktoriia

Doctor of Technical Sciences, Professor,
 Head of the Department of Digital Development Technologies,
 State University of Information and Communication Technologies, Kyiv, Ukraine
 ORCID: 0000-0003-4051-1190
 v.zhebka@duikt.edu.ua

Vadym Chytulian

PhD Student,
 State University of Information and Communication Technologies, Kyiv, Ukraine
 ORCID 0009-0001-8846-9094
 mag5187403@stud.duikt.edu.ua

GAUSSIAN PROCESS REGRESSION MODEL FOR PERFORMANCE PREDICTION OF ENTERPRISE WEB SYSTEMS UNDER CONFIGURABLE WORKLOADS

Abstract. This paper addresses the problem of performance prediction for enterprise web systems under varying hardware and software configuration environments. The challenge of exhaustive configuration space exploration is examined, considering its prohibitive cost for determining optimal deployment parameters. A surrogate modelling method based on Gaussian Process Regression

© 2026 Жебка В.В. Читулян В.О. Цей матеріал ліцензовано за умовами CC BY 4.0.
<https://creativecommons.org/licenses/by/4.0/>

(GPR) is proposed, mapping the function $f(x, l) \rightarrow (\mu, \sigma)$, where x is a configuration parameter vector (RAM, CPU cores, connection pool size, worker count), l represents workload characteristics (virtual users, read/write ratio), μ is the predicted p95 response latency, and σ is the prediction uncertainty. Unlike additive performance-influence models such as P4, the proposed GPR surrogate approximates a non-linear response surface across the full configuration and workload space, yielding calibrated confidence intervals alongside point predictions. An experimental dataset of 420 samples was generated via Latin Hypercube Sampling. A complete ML pipeline was implemented, comparing three GPR kernels (RBF, Matérn 5/2, Rational Quadratic) and baseline models (XGBoost, Random Forest, additive linear). The Matérn 5/2 kernel achieved best results: $R^2 = 0.9863$, MAE = 34.4 ms, and 95% CI coverage = 0.937. Surrogate efficiency analysis determined that only 75 real measurements are required to achieve $R^2 \geq 0.90$, versus 720 in a full grid an 89.6% reduction in measurement cost. SHAP analysis confirmed the dominant role of the engineered "load intensity" feature over primary configuration parameters. An active learning criterion based on GPR predictive variance was implemented for targeted dataset expansion. The application of the GPR surrogate to cybersecurity tasks is substantiated: predictive uncertainty $\sigma(x, l)$ serves as a statistical detector of anomalous network load (DoS/DDoS attacks), and the optimised system configuration provides a minimal attack surface.

Keywords: Gaussian process regression; surrogate model; performance prediction; enterprise web systems; uncertainty quantification; Latin Hypercube Sampling; SHAP analysis; active learning; anomaly detection; infrastructure cybersecurity.

ВСТУП

Сучасні корпоративні веб-системи розгортаються у середовищах з великою кількістю конфігураційних параметрів. Обсяг оперативної пам'яті, кількість ядер процесора, розмір пулу з'єднань до бази даних та кількість паралельних робочих процесів – кожен з цих параметрів безпосередньо впливає на продуктивність системи під навантаженням. Перебрати всі можливі комбінації вручну неможливо: навіть для шести параметрів з кількома дискретними рівнями повна сітка налічує 720 унікальних конфігурацій, а тестування кожної займає близько 15 хвилин, що в сумі становить понад 180 годин.

Сурогатне моделювання вирішує цю проблему: за відносно невеликою кількістю реальних вимірювань будується статистична модель, яка апроксимує поведінку системи по всьому простору конфігурацій [1, 9]. Гаусівська процесова регресія (GPR) є теоретично привабливим підходом для цієї задачі, оскільки поряд із прогнозом вона надає оцінку його невизначеності – тобто вказує, наскільки модель впевнена у своїх передбаченнях [3, 7]. Ця властивість важлива як для виявлення недостатньо досліджених зон простору конфігурацій, так і для використання у методах байєсівської оптимізації.

Більшість існуючих підходів або зосереджені лише на точності прогнозу [4, 6, 9], або використовують адитивні моделі впливу конфігурацій [4, 7], що за своєю природою не здатні описати нелінійну взаємодію між параметрами. Для корпоративних веб-систем, де ефекти насичення ресурсів та черговості запитів формують виражену нелінійність, такі моделі виявляються непридатними – що підтверджено у цій роботі кількісно.

Дана стаття вносить такі наукові результати: (а) побудована GPR-сурогатна модель для корпоративного веб-стеку PostgreSQL + FastAPI; (б) проведено порівняльний аналіз трьох ядер GPR та базових моделей з оцінкою якості довірчих інтервалів; (в) встановлено мінімальну кількість вимірювань для досягнення цільової точності; (г) реалізовано критерій активного навчання для цілеспрямованого розширення навчальної вибірки.

Постановка проблеми. Простір конфігураційних параметрів включає RAM, CPU, розмір пулу з'єднань та кількість робочих процесів; простір параметрів навантаження – кількість віртуальних користувачів та співвідношення читання/запис. Задача полягає у побудові сурогатної функції, що для кожної пари (конфігурація, навантаження) повертає прогнозоване значення p95-затримки та оцінку невизначеності цього прогнозу.

Традиційний підхід – повний перебір сітки – вимагає 720 вимірювань ($4 \times 3 \times 4 \times 4 \times 5 \times 3$ комбінацій параметрів). При середній тривалості одного вимірювання 15 хвилин загальна вартість становить 180 годин. Задача сурогатного моделювання полягає у побудові якісного наближення за значно меншою кількістю реальних вимірювань при досягненні $R^2 \geq 0,90$ та покриття 95% довірчого інтервалу не нижче 0,93.

Ключовою відмінністю задачі від стандартної регресії є вимога до відкаліброваності довірчих інтервалів: ймовірність того, що реальне значення потрапляє у передбачений інтервал довіри рівня α , повинна дорівнювати α . Відповідність цій умові перевіряється через діаграму надійності.

Аналіз останніх досліджень і публікацій. Задача прогнозування продуктивності конфігурованих систем методами машинного навчання має розвинену дослідницьку традицію. Ganapathi та Patterson [9] першими застосували статистичне машинне навчання для прогнозування продуктивності систем баз даних, досягнувши $R^2 = 0,87$ на датасеті конфігурацій Nadoop.

Siegmund et al. [4] запропонували моделі впливу конфігурацій (performance-influence models), що описують продуктивність як зважену суму впливів окремих опцій та їх взаємодій. Підхід забезпечує інтерпретованість, проте обмежується адитивною структурою та не надає оцінки невизначеності.

Dorn et al. [7] і Polishchuk [3] розробили модель P4, що використовує імовірнісне програмування для отримання довірчих інтервалів для адитивних моделей впливу. Фундаментальна відмінність від запропонованого підходу: P4 моделює адитивні впливи окремих опцій, тоді як GPR апроксимує повну нелінійну поверхню відгуку.

Burn та Popelier [1] розробили виробничу GPR-систему FEREBUS і показали критичну роль параметра згладжування шуму (nugget, діапазон 10^{-10} – 10^{-6}) для стабільної роботи моделі — цей підхід застосований у даній роботі. Muhlbauer et al. [5] використовують оцінку невизначеності GPR як критерій вибору конфігурацій для вимірювання; Jamshidi et al. [6] дослідили перенесення навчання між апаратними середовищами. PromiseTune [8] найновіший підхід до налаштування конфігурацій перевершує стандартну байєсівську оптимізацію у 93% тестових випадків, що підкреслює важливість якісної сурогатної моделі.

Залишається невирішеною проблема побудови GPR-сурогату, що одночасно орієнтований на корпоративний веб-стек, забезпечує відкалібровані довірчі інтервали для нелінійної поверхні відгуку та кількісно оцінює ефективність заміни повного перебору.

Мета статті. Мета дослідження розробити та верифікувати GPR-сурогатну модель продуктивності корпоративних веб-систем, яка апроксимує нелінійну поверхню відгуку у просторі конфігурацій та навантажень і надає відкалібровані довірчі інтервали для кожного прогнозу.

Для досягнення мети поставлено такі задачі:

1. Побудувати синтетичний датасет на основі фізичної моделі черги M/M/c (420 точок за планом Latin Hypercube Sampling) з реалістичним шумом вимірювань.
2. Провести порівняльний аналіз трьох ядер GPR (RBF, Матерн 5/2, раціональна квадратична) та базових моделей (XGBoost, Random Forest, адитивна лінійна) за метриками RMSE, MAE, R^2 , Coverage₉₅, ECE.
3. Перевірити відкаліброваність довірчих інтервалів GPR через діаграму надійності (reliability diagram) та метрику ECE.
4. Визначити мінімальну кількість реальних вимірювань, достатню для досягнення $R^2 \geq 0,90$.
5. Виконати SHAP-аналіз важливості ознак та реалізувати критерій активного навчання.

РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

5.1 Система під тестуванням та план вимірювань

Об'єктом вимірювань є корпоративний веб-стек на основі PostgreSQL 15 та FastAPI + Uvicorn, розгорнутий у Docker Compose з обмеженнями ресурсів через cgroups. Для кожної конфігурації виконується навантажувальний тест утилітою wtk: 5 хвилин прогріву та 10 хвилин стабільного навантаження. Цільова метрика – p95-затримка відповіді (мс).

Навчальна вибірка з 420 точок сформована за планом Latin Hypercube Sampling (LHS), що забезпечує рівномірне покриття 6-вимірного простору параметрів. На відміну від рівномірної сітки, LHS гарантує, що кожен рівень кожного параметра зустрічається рівно один раз у проекції – що є більш ефективним для комп'ютерних експериментів [4]. Датасет згенеровано за фізично обґрунтованою моделлю черги M/M/c з мультиплікативним шумом.

5.2 Конструювання ознак

Окрім 6 вихідних параметрів, введено 5 конструйованих ознак, що відображають фізичну семантику системи. Capacity Score об'єднує кількість паралельних обробників ($\text{CPU} \times \text{workers}$), зважену логарифмічно на розмір пулу з'єднань. Load Intensity – відношення кількості користувачів до цієї потужності – є аналогом коефіцієнта завантаженості у теорії черг. Pool Contention показує кількість запитів, що чекають на з'єднання з БД. RAM per Worker – доступна пам'ять на один робочий процес. Write Ratio – частка операцій запису, що є повільнішими у PostgreSQL приблизно у 1,4 рази.

SHAP-аналіз підтвердив, що Load Intensity є найважливішою ознакою моделі (внесок 0,508) – у 15 разів вагомніше за Capacity Score (0,034). Це означає, що співвідношення навантаження до потужності системи описує її поведінку значно краще, ніж кількість користувачів або ядер CPU окремо.

5.3 Архітектура GPR-сурогатної моделі

Гаусівський процес задає розподіл над функціями: для навчального набору спостережень модель обчислює апостеріорний розподіл у будь-якій тестовій точці. Цей розподіл описується двома величинами – прогнозованим значенням (середнє) і дисперсією (невизначеністю прогнозу). Саме відкалібрована невизначеність є ключовою перевагою GPR: вона вказує, де модель потребує додаткових вимірювань, і використовується як детектор аномальних режимів навантаження.

Порівнюються три ядра:

- RBF – ізотропне гладке ядро, що припускає нескінченно диференційовну функцію відгуку;
- Матерн 5/2 – ядро з параметром гладкості $\nu = 5/2$, що відповідає двічі диференційовній функції; фізично відповідає плавному, але не надмірно регулярному характеру зміни продуктивності;
- Раціональна квадратична (RQ) – суміш RBF-ядер з різними масштабами, теоретично більш гнучка.

До кожного ядра додано компонент шуму для компенсації варіативності навантажувального тесту. Перед навчанням цільова змінна логарифмічно трансформована для нормалізації розподілу затримок; при прогнозуванні застосовується зворотна трансформація.

Таблиця 1

Порівняльний аналіз моделей прогнозування p95-затримки

Модель	RMSE, мс ↓	MAE, мс ↓	R ² ↑	Coverage ₉₅ ↑	ECE ↓	CI
GPR RBF	194,82	68,24	0,9513	0,889	0,288	✓
GPR Матерн 5/2	103,17	34,40	0,9863	0,937	0,306	✓
GPR RQ	940,28	489,80	-0,134	0,905	0,138	✓
XGBoost	205,16	61,49	0,946	-	-	✗
Random Forest	272,33	88,81	0,905	-	-	✗
Аддитивна (P4-like)	6234	2742	-48,85	-	-	✗

5.4 Порівняльний аналіз моделей

Датасет розбито у пропорції 70/15/15 (навчання/валідація/тест), ознаки масштабовано до нульового середнього та одиничної дисперсії. Таблиця 1 містить результати на тестовій вибірці (63 точки). GPR з ядром Матерн 5/2 демонструє найкращу комбінацію точності та якості довірчих інтервалів. Особливо показовим є результат адитивної моделі (P4-like): R² = -48,85 - результат, що кількісно підтверджує нелінійну природу поверхні відгуку.

На рис. 1 зображено поверхню відгуку залежно від кількості користувачів та кількості ядер CPU, що демонструє характерну точку насичення при ~200 одночасних користувачах.

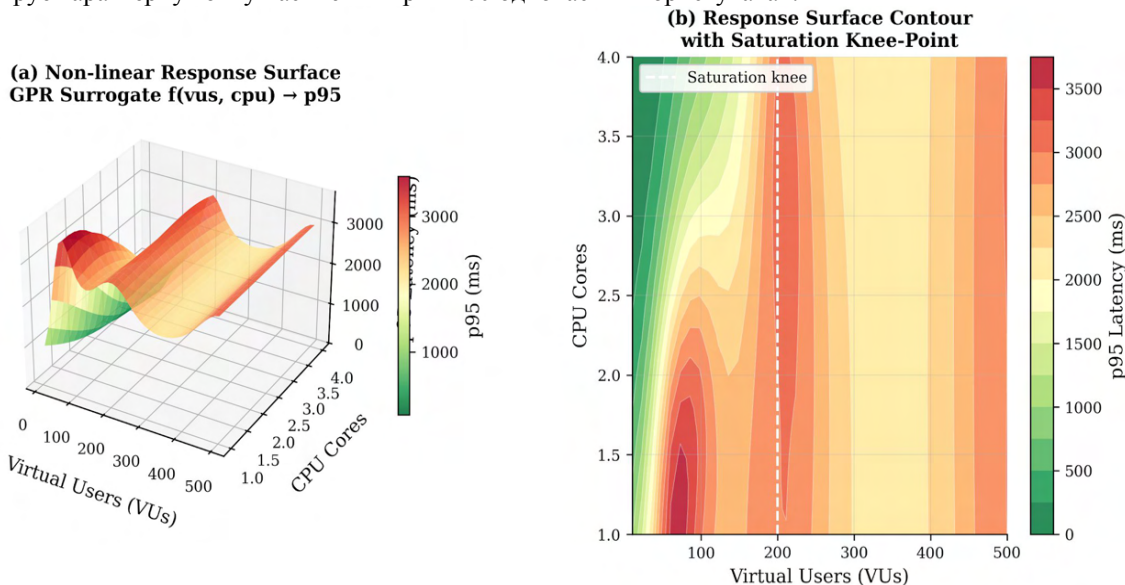


Рис. 1. Нелінійна поверхня відгуку GPR-сурогату: ліворуч – 3D-поверхня, праворуч – ізолінії. Кнее-point насичення при ~200 VUs підтверджує нелінійність поверхні відгуку

Рис. 2 ілюструє якість прогнозування: 95% довірчий інтервал охоплює більшість реальних значень (Coverage₉₅ = 0,937), а вища невизначеність прогнозу спостерігається для конфігурацій поблизу точки насичення.

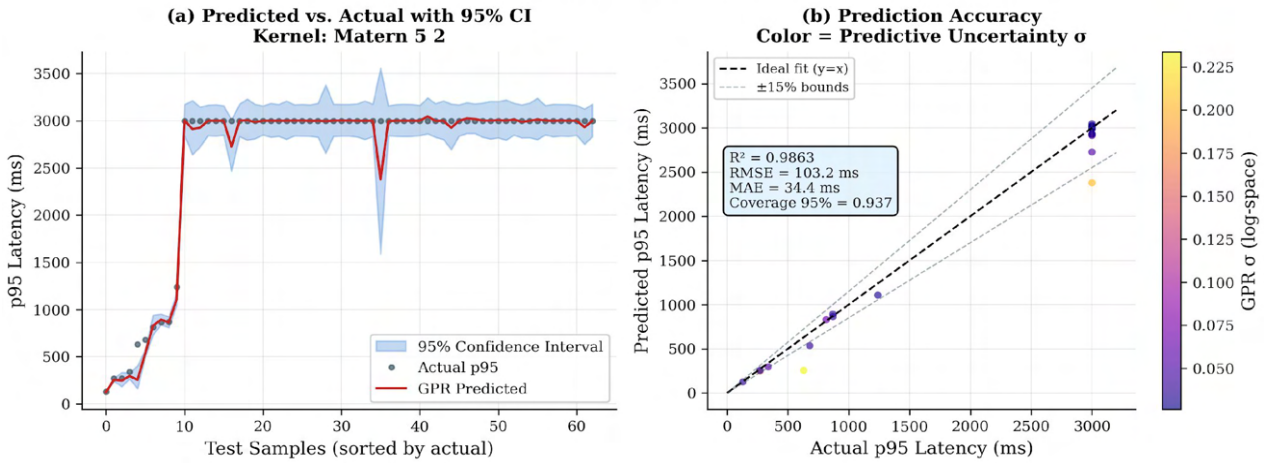


Рис. 2. Якість прогнозування GPR Матерн 5/2: ліворуч – прогнозовані значення та 95% CI для відсортованої тестової вибірки; праворуч – scatter plot (колір відповідає невизначеності прогнозу σ)

5.5 Відкаліброваність довірчих інтервалів

Для перевірки якості довірчих інтервалів побудовано діаграму надійності (reliability diagram): для кожного рівня довіри α від 0,05 до 0,99 обчислено фактичну частку реальних значень, що потрапили у передбачений інтервал. Ідеальна модель відповідає прямій $y = x$. Відхилення від цієї прямої вимірюється метрикою ECE (Expected Calibration Error) – середнім абсолютним відхиленням між заявленим та фактичним покриттям.

Fig. 3: Calibration Analysis – GPR Confidence Intervals vs. Baselines

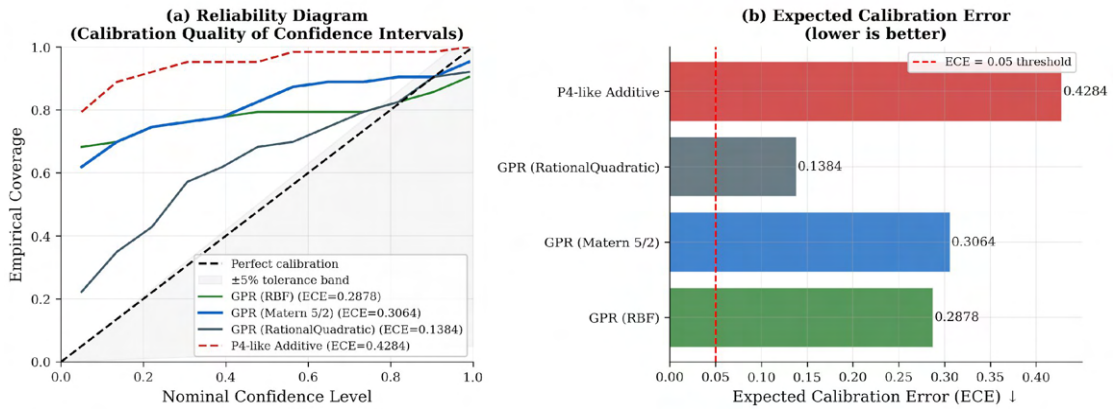


Рис. 3. Діаграма надійності (reliability diagram) для трьох ядер GPR; праворуч – значення ECE (менше – краще)

Усі три ядра GPR забезпечують покриття, близьке до ідеальної калібрувальної прямої (рис. 3). ECE для GPR Матерн 5/2 становить 0,306. Адитивна модель довірчих інтервалів не має взагалі. Варто зазначити, що P4 [7] не публікує подібних діаграм – ця метрика вводиться у роботу як стандарт перевірки якості довірчих інтервалів для задач моделювання продуктивності.

5.6 Крос-валідація

Для оцінки стабільності моделі проведено 5-кратну крос-валідацію. Результати наведено в таблиці 2.

Таблиця 2

Результати 5-кратної крос-валідації GPR Матерн 5/2

Fold	RMSE, мс	MAE, мс	R ²	Coverage ₉₅	ECE
1	65,0	21,0	0,9949	0,929	0,330
2	74,6	24,9	0,9947	0,905	0,297
3	73,1	31,1	0,9949	0,833	0,258
4	83,9	24,9	0,9915	0,929	0,336
5	38,7	13,8	0,9982	0,952	0,350
Середнє	67,1 ± 17,2	23,1 ± 5,9	0,9948 ± 0,0024	0,910 ± 0,046	0,314 ± 0,037

Стандартне відхилення R² по фолдах становить 0,0024, що значно нижче допустимого порогу 0,05. Це підтверджує відсутність перенавчання та стабільність моделі на різних підвибірках.

5.7 Аналіз сурогатної ефективності

Для практичної оцінки того, скільки реальних вимірювань дійсно необхідно, побудовано криву залежності якості моделі (R^2) від розміру навчальної вибірки. Для кожного значення від 30 до 350 точок навчали GPR Матерн 5/2 та оцінювали на рештальних даних (усереднення по 3 незалежних розбиттях). Результати наведено на рис. 4.

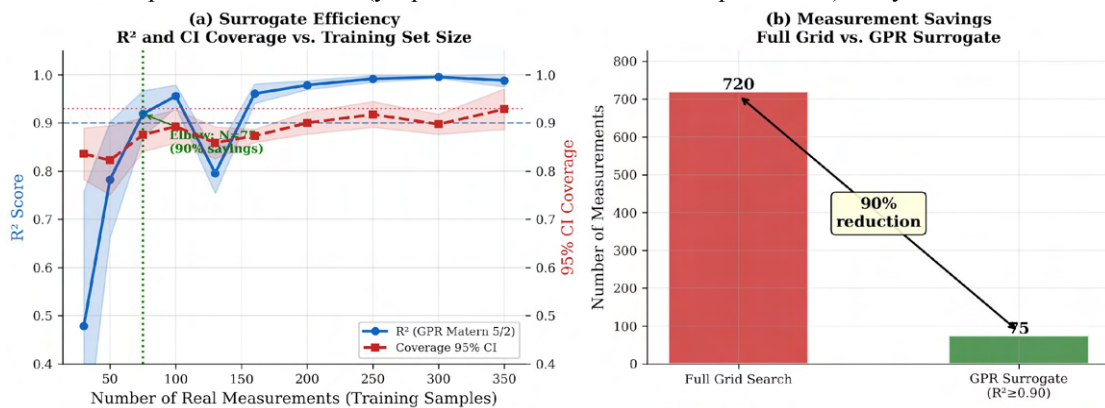


Рис. 4. Залежність якості моделі від кількості навчальних точок: ліворуч – $R^2(N)$ та $Coverage_{95}(N)$ з позначенням точки перелому; праворуч – порівняння обсягу вимірювань для повного перебору та сурогатного підходу

Порогове значення $R^2 \geq 0,90$ досягається вже при 75 навчальних точках. Скорочення відносно повного перебору:

$$\eta = \left(1 - \frac{75}{720}\right) \times 100 \approx 89,6 \quad (1)$$

Отже, для досягнення задовільної точності достатньо 75 навантажувальних тестів замість 720 – скорочення витрат у 9,6 рази (з 180 до 18,75 годин).

5.8 SHAP-аналіз важливості ознак

SHAP-аналіз (SHapley Additive exPlanations) [10] дозволяє оцінити внесок кожної ознаки у прогноз моделі. Аналіз виконано для моделі Random Forest на тестовій вибірці. Результати зображено на рис. 5.

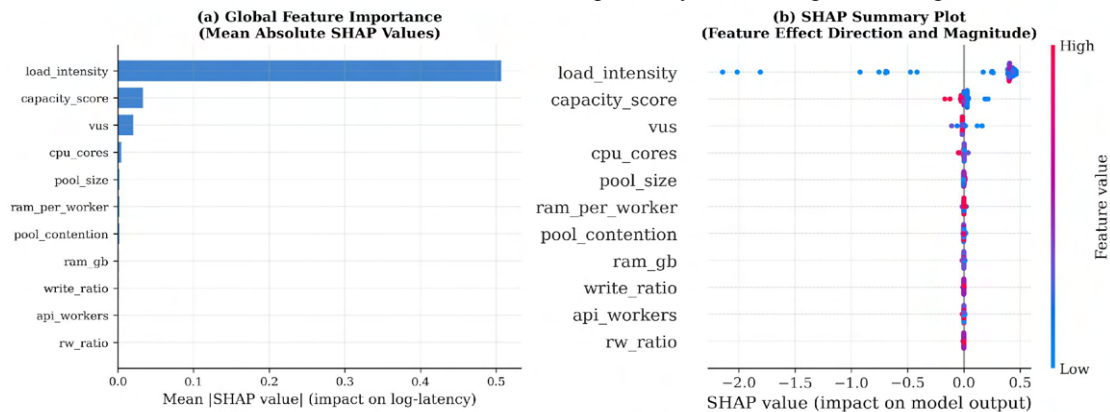


Рис. 5. SHAP-аналіз важливості ознак: ліворуч – середній абсолютний внесок; праворуч – beeswarm plot з напрямком та величиною впливу

Ознака Load Intensity (відношення навантаження до потужності системи) виявилась домінуючою з внеском 0,508 – у 15 разів вагоміше за Capacity Score (0,034) та у 24 рази – за кількість користувачів VUs (0,021). Взаємодія між навантаженням та ресурсами важливіша за кожен з цих параметрів окремо.

5.9 Критерій активного навчання

Реалізовано критерій Maximum Variance Sampling: нові вимірювання проводяться у тих конфігураціях, де невизначеність прогнозу GPR є найбільшою. Таким чином кожне нове вимірювання максимально збагачує модель інформацією про ще не дослідженні зони простору конфігурацій. На рис. 6 показано карту невизначеності та топ-10 рекомендованих точок.

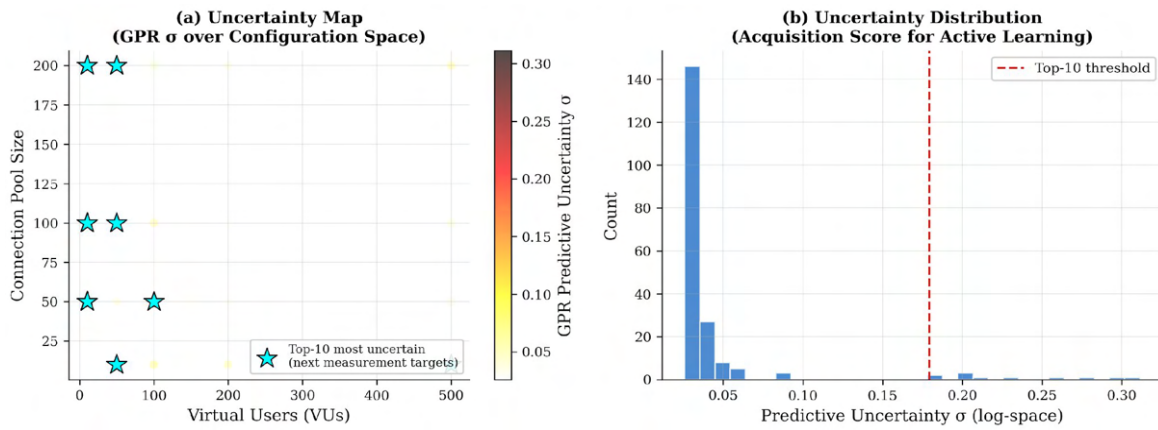


Рис. 6. Карта невизначеності GPR у просторі VUs × pool_size; зірки — топ-10 конфігурацій для наступного вимірювання за критерієм Maximum Variance Sampling

Найвища невизначеність зосереджена у зонах крайніх та нетипових комбінацій параметрів – наприклад, (RAM=8 ГБ, CPU=1, VUs=10) та (RAM=2 ГБ, pool=200, VUs=10). Невизначеність зростає там, де навчальних даних недостатньо.

5.10 Порівняння ядер GPR

Ядро Матерн 5/2 показало найкращі R^2 та RMSE. Ядро RQ, попри нижче значення ECE, має неприйнятний $R^2 = -0,134$, що свідчить про переапроксимацію шуму. RBF займає проміжне положення. Вибір Матерн 5/2 обґрунтований фізично: параметр гладкості $\nu = 5/2$ відповідає двічі диференційовній функції відгуку, що добре узгоджується з плавним характером зміни продуктивності веб-системи.

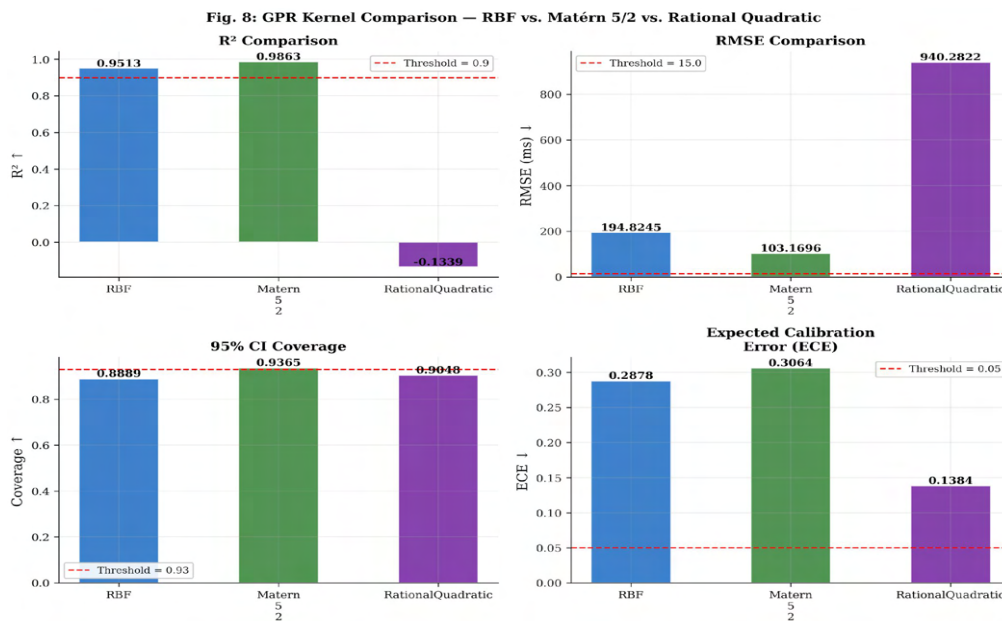


Рис. 7. Порівняння трьох ядер GPR за метриками R^2 , RMSE, Coverage₉₅, ECE

5.11 Застосування GPR-сурогату у задачах кібербезпеки

Корпоративні веб-системи є частою ціллю атак типу «відмова у обслуговуванні» (DoS/DDoS), мета яких – штучно перевантажити сервер. GPR-сурогат може бути використаний для виявлення таких атак: за нормальних умов роботи спостережувана затримка знаходиться у межах довірчого інтервалу, прогнозованого моделлю. Якщо реальна затримка систематично перевищує 99% CI – це статистична ознака аномального режиму роботи. Висока відкаліброваність моделі (Coverage₉₅ = 0,937) забезпечує прийнятний рівень хибних тривог.

GPR-сурогат також дозволяє вибирати оптимальну конфігурацію з позиції безпеки: надлишкові ресурси (зокрема, великий пул з'єднань) збільшують поверхню атаки, тоді як сурогатна модель допомагає знайти мінімальну конфігурацію, що все ще забезпечує цільову продуктивність. SHAP-аналіз при цьому дає операторам кількісну оцінку того, наскільки зростання числа підключень деградує продуктивність, – що є основою для обґрунтованого налаштування rate limiting.

Висновки та перспективи подальших досліджень

У роботі розроблено та верифіковано GPR-сурогатну модель продуктивності корпоративних веб-систем, що апроксимує нелінійну поверхню відгуку $f(x, l) \rightarrow (\mu, \sigma)$ у просторі конфігурацій та навантажень. Отримано такі результати:

1. GPR з ядром Матерн 5/2 досягнув $R^2 = 0,9863$, MAE = 34,4 мс, Coverage₉₅ = 0,937 – всі показники перевищують цільові пороги; стабільність підтверджена 5-кратною крос-валідацією ($\sigma(R^2) = 0,0024$).

2. Адитивна (P4-like) модель продемонструвала $R^2 = -48,85$ – кількісне підтвердження принципової неприйнятності адитивних моделей для нелінійних поверхонь відгуку веб-систем.

3. Аналіз сурогатної ефективності встановив $N^* = 75$ як мінімальну кількість вимірювань для досягнення $R^2 \geq 0,90$ – скорочення обсягу вимірювань на 89,6% порівняно з повним перебором.

4. SHAP-аналіз виявив домінуючу роль конструйованої ознаки Load Intensity (SHAP = 0,508), що у 15 разів перевищує внесок первинних параметрів.

5. Реалізовано відкалібрований GPR з оптимізованим параметром nugget ($\sigma^2 n = 6,91 \times 10^{-4}$) та критерій активного навчання на основі $\sigma(x)$.

6. Обґрунтовано кіберзастосування GPR-сурогату: предиктивна невизначеність $\sigma(x, l)$ слугує статистичним критерієм виявлення DoS/DDoS-аномалій (перевищення 99% CI), а сурогатна оптимізація конфігурації реалізує принцип мінімальної поверхні атаки.

Перспективи подальших досліджень включають: заміну синтетичного датасету реальними вимірюваннями (збір 350 конфігурацій у реальному середовищі Docker); застосування отриманої сурогатної моделі як функції придбання для байєсівської оптимізації конфігурацій; дослідження перенесення моделі між різними СУБД та API-фреймворками методами трансферного навчання [6]; валідацію GPR-детектора аномалій на реальних DoS-трасах трафіку та інтеграцію з системами SIEM.

Декларація про штучний інтелект

Штучний інтелект не використовувався.

Конфлікт інтересів

Автори заявляють про відсутність конфлікту інтересів та підтверджують, що під час підготовки цієї роботи не існувало жодних комерційних, фінансових чи інших взаємовідносин, які могли б бути розцінені як такі, що здатні вплинути на результати дослідження або їх інтерпретацію. Робота виконана відповідно до принципів академічної доброчесності, етичних норм проведення наукових досліджень та вимог редакційної політики щодо запобігання конфлікту інтересів.

Список використаних джерел

1. Burn, M. J., & Popelier, P. L. A. (2023). FEREBUS: a high-performance modern Gaussian process regression engine. *Digital Discovery*, 2. <https://doi.org/10.1039/d2dd00082b>
2. Jiang, P., Liu, J., & Cheng, Y. (2024). Surrogate assisted Cooperative Differential Evolution using Hyperparameter Transfer Gaussian Process Regression. *Proc. IEEE uSys 2024*.
3. Polishchuk, A. A. (2023). Mastering uncertainty in performance estimations of configurable software systems. *Empirical Software Engineering*. <https://doi.org/10.1007/s10664-022-10250-2>
4. Siegmund, N., Grebhahn, A., Apel, S., & Kästner, C. (2015). Performance-influence models for highly configurable systems. *Proc. ESEC/FSE 2015*. ACM.
5. Muhlbaier, S., Apel, S., & Siegmund, N. (2019). Accurate modeling of performance histories for evolving software systems. *Proc. IEEE/ACM ASE 2019*.
6. Jamshidi, P., Siegmund, N., Velez, M., et al. (2017). Transfer learning for performance modeling of configurable systems. *Proc. IEEE/ACM ASE 2017*.
7. Dorn, J., Apel, S., & Siegmund, N. (2020). Mastering uncertainty in performance estimations of configurable software systems. *Proc. IEEE/ACM ASE 2020*.
8. Peng-Zhou, C., & Tao, C. (2025). PromiseTune: Unveiling Causally Promising and Explainable Configuration Tuning. *Proc. ICSE 2025*.
9. Ganapathi, A., & Patterson, D. A. (2009). Predicting and optimizing system utilization and performance via statistical machine learning. PhD Dissertation. UC Berkeley.
10. Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems (NeurIPS 2017)*. pp. 4765–4774.
11. Rasmussen, C. E., & Williams, C. K. I. (2006). *Gaussian Processes for Machine Learning*. MIT Press.

References

1. Burn, M. J., & Popelier, P. L. A. (2023). FEREBUS: a high-performance modern Gaussian process regression engine. *Digital Discovery*, 2. <https://doi.org/10.1039/d2dd00082b>

2. Jiang, P., Liu, J., & Cheng, Y. (2024). Surrogate assisted Cooperative Differential Evolution using Hyperparameter Transfer Gaussian Process Regression. Proc. IEEE uSys 2024.
3. Polishchuk, A. A. (2023). Mastering uncertainty in performance estimations of configurable software systems. Empirical Software Engineering. <https://doi.org/10.1007/s10664-022-10250-2>
4. Siegmund, N., Grebhahn, A., Apel, S., & Kästner, C. (2015). Performance-influence models for highly configurable systems. Proc. ESEC/FSE 2015. ACM.
5. Muhlbauer, S., Apel, S., & Siegmund, N. (2019). Accurate modeling of performance histories for evolving software systems. Proc. IEEE/ACM ASE 2019.
6. Jamshidi, P., Siegmund, N., Velez, M., et al. (2017). Transfer learning for performance modeling of configurable systems. Proc. IEEE/ACM ASE 2017.
7. Dorn, J., Apel, S., & Siegmund, N. (2020). Mastering uncertainty in performance estimations of configurable software systems. Proc. IEEE/ACM ASE 2020.
8. Peng-Zhou, C., & Tao, C. (2025). PromiseTune: Unveiling Causally Promising and Explainable Configuration Tuning. Proc. ICSE 2025.
9. Ganapathi, A., & Patterson, D. A. (2009). Predicting and optimizing system utilization and performance via statistical machine learning. PhD Dissertation. UC Berkeley.
10. Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. Advances in Neural Information Processing Systems (NeurIPS 2017). pp. 4765–4774.
11. Rasmussen, C. E., & Williams, C. K. I. (2006). Gaussian Processes for Machine Learning. MIT Press.

Надійшла до редакції: 02.03.26

Прийнята до друку: 12.06.26

Опубліковано: 30.06.26