

Фісун Олена Сергіївна

Київський національний університет імені Тараса Шевченка, м. Київ

ORCID 0009-0009-6640-3818

ЗАБЕЗПЕЧЕННЯ ФУНКЦІОНАЛЬНОЇ СТІЙКОСТІ ПРОГРАМНО-КЕРОВАНОЇ КОМП'ЮТЕРНОЇ МЕРЕЖІ НА ОСНОВІ АВТОРЕГРЕСІЙНИХ МЕТОДІВ МАШИННОГО НАВЧАННЯ

Анотація: У статті розглянуто проблему забезпечення функціональної стійкості програмно-керованих комп'ютерних мереж (Software Defined Networks, SDN) в умовах стохастичних коливань трафіку та динамічних змін мережесевих потоків. Проаналізовано існуючі підходи до підвищення відмовостійкості SDN, зокрема методи резервування, багатоконтролерні архітектури, гібридні моделі захисту й відновлення, а також алгоритми машинного навчання для прогнозування навантажень. Показано, що більшість класичних рішень орієнтовані на статичні моделі контролерів і не враховують короткотермінові флуктуації трафіку, що призводить до затримок і втрат пакетів у критичних ділянках мережі. Метою дослідження є розроблення методу підвищення стійкості SDN на основі авторегресійних підходів машинного навчання з урахуванням статистичних властивостей трафіку. У роботі запропоновано удосконалену модель прогнозування параметрів навантаження, яка поєднує класичні AR-моделі з методом розкладання випадкового процесу за схемою Карунена–Лоева. Такий підхід забезпечує більш точне відтворення динаміки трафіку та дозволяє виявляти моменти наближення до граничних режимів роботи вузлів SDN. Результати моделювання підтверджують ефективність розробленого методу: середня нормалізована похибка прогнозування (NRMSE) не перевищує 2–3% навіть у разі різких сплесків навантаження, тоді як для класичних методів вона сягає 25–40%. Запропонований підхід може бути використаний для адаптивного балансування навантаження між контролерами, своєчасного реагування на перевантаження та підвищення рівня якості обслуговування (QoS). Таким чином, отримані результати створюють наукове підґрунтя для побудови інтелектуальних систем керування SDN з підвищеною функціональною стійкістю.

Ключові слова: програмно-керована мережа (SDN), функціональна стійкість, авторегресія, машинне навчання, розкладання Карунена–Лоева, індивідуальне прогнозування, аномалії трафіку, інтелектуальні методи аналізу.

Fisun Olena

Taras Shevchenko National University of Kyiv, Kyiv

ORCID 0009-0009-6640-3818

ENSURING FUNCTIONAL RESILIENCE OF A SOFTWARE-DEFINED COMPUTER NETWORK BASED ON AUTOREGRESSIVE MACHINE LEARNING METHODS

Abstract: The article studies the problem of ensuring the functional resilience of software-defined computer networks (SDN) in conditions of stochastic fluctuations in traffic and dynamic changes in network flows. Existing approaches to increasing the fault tolerance of SDN are analyzed, in particular, redundancy methods, multi-controller architectures, hybrid protection and recovery models, as well as machine learning algorithms for load forecasting. It is shown that most classical solutions are focused on static controller models and do not take into account short-term traffic fluctuations, which leads to delays and packet loss in critical network sections. The aim of the study is to develop a method for increasing the resilience of SDN based on autoregressive machine learning approaches taking into account the statistical properties of traffic. The paper proposes an improved model for predicting load parameters, which combines classical AR models with the method of decomposition of a random process according to the Karunen-Loev expansion scheme. This approach provides a more accurate reproduction of traffic dynamics and allows you to detect moments of approaching the limit modes of operation of SDN nodes. The simulation results confirm the effectiveness of the developed method: the normalized mean prediction error (NRMSE) does not exceed 2–3% even in the case of sharp load spikes, while for classical methods it reaches 25–40%. The proposed approach can be used for adaptive load balancing between controllers, timely response to overload and increasing the level of quality of service (QoS). Thus, the results obtained create a scientific basis for building intelligent SDN control systems with increased functional resilience.

Keywords: Software-Defined Networking (SDN), functional resilience, autoregression, machine learning, Karunen-Loev Expansion, individual forecasting, traffic anomalies, intelligent analysis methods.

1. Вступ

Різке зростання обсягів трафіку та розширення спектра послуг для великої кількості користувачів суттєво вплинули на структуру сучасних мереж передачі даних. Додатковими факторами стали

створення високопродуктивних кластерів для обробки великих даних і розгортання масштабованих віртуалізованих середовищ для надання хмарних сервісів. Усе це зумовило зміну вимог до мережевої інфраструктури. Одним із сучасних підходів до побудови корпоративних мереж є концепція програмно-керованих мереж (SDN), що функціонують на мережевому рівні. Така концепція забезпечує створення автоматизованих, програмованих, гнучких і економічно ефективних систем зв'язку. Завдяки цьому вдається комплексно вирішувати накопичені проблеми, зокрема у сфері мережевої та інформаційної безпеки [1].

Мережі SDN поєднують апаратну інфраструктуру та програмне централізоване управління для контролю трафіку в реальному часі. Функціональна стійкість SDN означає здатність підтримувати якість обслуговування та параметри трафіку в допустимих межах навіть за пікових навантажень, різких змін потоків або кібератак. Стабільність мережі визначають правильність і безперервність правил маршрутизації та балансування, що забезпечує передбачувану якість сервісів і мінімальний вплив зовнішніх загроз.

2. Аналіз літературних даних і постановка проблеми

Дослідженню стійкості функціонування програмно-керованих мереж (SDN) присвячено достатньо велику кількість публікацій. У роботі [2] зазначено, що централізоване керування в SDN створює ризики масштабованості та єдину точку відмови, що знижує стійкість мережі. Автори пропонують підхід, орієнтований на підвищення надійності контролера, захист топології від збоїв і протидію зловмисним атакам.

Дослідження [3] присвячене моделі безпечної багатошляхової маршрутизації фрагментованих повідомлень у площині даних SDN. Проведений аналіз показав, що застосування резервування під час передавання даних дозволяє ефективніше балансувати навантаження між маршрутами та зменшувати ризики компрометації. У публікації [4] розроблено концепцію змішаної швидкої стійкості (MFR) для промислових SDN, яка поєднує переваги відновлення та захисту. Використання динамічної структури хеш-таблиці дозволяє зменшити час відновлення з'єднання та втрату пакетів під час збоїв. У статті [5] запропоновано архітектуру SDN-microSENSE для підвищення стійкості "розумних мереж" (Smart Grid). Вона базується на трирівневій структурі, що включає оцінку ризиків, виявлення вторгнень і самовідновлення, які взаємодіють із SDN-контролером для швидкої нейтралізації атак. Робота [6] аналізує вразливості SDN і хмарних мереж, акцентуючи увагу на збоях контролерів. Автори використовують методи машинного навчання (зокрема, SVM) для класифікації збоїв і пропонують структуру, що інтегрує машинне навчання в систему управління мережею для підвищення відмовостійкості.

У дослідженні [7] розглянуто механізми відновлення SDN після збоїв із використанням протоколів OpenFlow. Запропонований підхід охоплює площини даних, керування та застосувань, забезпечуючи швидке виявлення та усунення відмов. Нарешті, у [8] представлено алгоритм динамічного масштабування контролерів, який дозволяє розподіляти навантаження між ними в режимі реального часу. Це зменшує затримки обробки трафіку та запобігає перевантаженню окремих вузлів, що безпосередньо підвищує стійкість SDN.

Наведений огляд літератури показує, що більшість підходів спрямовані на усунення наслідків збоїв, тоді як менше уваги приділяється проактивному управлінню трафіком. Тому, для забезпечення функціональної стійкості SDN, перспективним напрямом досліджень є розробка методів короткотермінового та середньотермінового прогнозування навантаження у реальному часі. Це ставить задачу розробки ефективних алгоритмів прогнозування трафіку, здатних враховувати стохастичний характер навантаження та забезпечувати своєчасне коригування правил маршрутизації та балансування потоків.

3. Мета і задачі дослідження

Мета дослідження – підвищення функціональної стійкості програмно-керованої комп'ютерної мережі (SDN) шляхом розроблення та удосконалення методів короткотермінового прогнозування параметрів мережевого трафіку із використанням авторегресійних підходів машинного навчання. Реалізація поставленої мети дозволить забезпечити своєчасне виявлення потенційних перевантажень, запобігти відмовам SDN-контролера та підвищити ефективність розподілу мережевих ресурсів у динамічних умовах.

Для досягнення мети дослідження необхідно вирішити такі задачі:

- провести аналіз сучасних підходів до забезпечення стійкості SDN, зокрема методів відновлення, захисту та масштабування контролерів;

- дослідити можливості застосування авторегресійних моделей (AR, ARMA, ARIMA, SARIMA, FARIMA) та їх модифікацій для прогнозування трафіку в SDN;
- розробити модель прогнозування навантаження SDN-вузлів на основі авторегресійних методів із урахуванням стохастичного характеру мережових процесів;
- провести порівняльний аналіз ефективності традиційних методів прогнозування та розкладання Карунена–Лоева (KLE) щодо точності відтворення динаміки трафіку.

4. Загальна модель функціональної стійкості SDN

Функціональна стійкість є складовою класичної теорії стійкості, яка широко досліджується у роботах [9, 10]. Більшість існуючих моделей цієї теорії базуються на звичайних диференціальних рівняннях, які дозволяють аналізувати різні аспекти стійкості систем. Для програмно-керованих мереж (SDN) доцільно спершу визначити загальну постановку задачі забезпечення стійкості, а потім уточнити поняття функціональної стійкості. Як зазначено у [11], *стійкість функціонування* описує поведінку системи у фазовому просторі при порівнянні незбуреного та збуреного станів

$$\forall \theta > 0 \Rightarrow \delta > 0, \rho(z_0, z'_0) < \delta \Rightarrow \rho[z(t, z_0), z(t, z'_0)] < \theta, \quad \forall t \in [0, \infty), \quad (1)$$

де $z_0 = z(0)$ – початкові фазові координати z_0 незбуреного руху; $z'_0 = z'(0)$ – фазові координати збуреного руху; ρ – метрика простору Z ; θ – допустиме відхилення.

В той же час, відповідно до [11], *функціональна стійкість* – це відхилення основних функцій від координат при збуреному та незбуреному русі

$$\forall \theta > 0 \Rightarrow \delta > 0, \rho(f(z_0), f(z'_0)) < \delta \Rightarrow \rho[f(z(t, z_0)), f(z(t, z'_0))] < \theta, \quad \forall t \in [0, \infty), \quad (2)$$

де $f(z)$ – деяка функція від фазових координат.

Базуючись на визначенні (2), у цій роботі під *функціональною стійкістю SDN* розуміється здатність мережі протягом заданого часу зберігати виконання основних функцій у межах нормативних вимог, в т.ч. за наявності відмов, несправностей чи кібератак.

Забезпечення функціональної стійкості SDN на основі прогнозуючого контролю. Модель (2) є узагальненою і потребує знання характеристик мережевого обладнання та стохастичних параметрів трафіку. Ці дані можна отримати зі статистики роботи обладнання або шляхом моніторингу трафіку SDN. Однак такий контроль відображає показники (байти, пакети, потоки) лише в окремі моменти часу $t = t_k$. Водночас необхідно забезпечити ефективну роботу мережі протягом певного проміжку часу θ . Тому під час моніторингу в SDN слід враховувати не лише поточний стан $t = t_k$, а і прогнозований період $t_k \leq s \leq t_k + \theta$.

Нормальне (штатне) функціонування SDN розуміється як перебування параметрів мережі в допустимих межах під час контролю t_k та їх збереження протягом заданого періоду $t_k + \theta$. У просторі станів SDN Ω можна виділити підпростір функціональності $\Omega_0 \subset \Omega$ – множину станів, за яких мережа виконує маршрутизацію, та підпростір нефункціональності $\Omega \setminus \Omega_0$ – множину станів непридатності. Як зазначено в [12], контроль функціональності $\Omega(t_k) \subset \Omega(t_k, \theta)$, є окремим випадком *прогнозуючого контролю*.

Після визначення області $\Omega(t_k, \theta)$ для задачі прогнозуючого контролю кожній події $\omega \in \Omega(t_k, \theta)$ слід зіставити ознаку стану мережі, як кількісну характеристику

$$e_\omega(s), \quad t_k \leq s \leq t_k + \theta, \quad (3)$$

що відображає випадковий процес зміни параметрів мережі в часі. Отже, функціонування SDN можна подати як випадковий процес $E(t)$ на інтервалі $t_k \leq s \leq t_k + \theta$.

Якщо задати область допуску E_0 , то керування функціонуванням SDN полягає в тому, щоб реалізація випадкового процесу $E(t)$ не виходила за її межі E_0 протягом інтервалу $[t_k, t_k + \theta]$:

$$e_\omega(s) \in E_0, t_k \leq s \leq t_k + \theta. \quad (4)$$

У роботі [13] зазначено, що для прогнозного контролю замість випадкового процесу $E(t)$ можна використовувати випадкову функцію $T(e)$, як часову міру процесу $E(t)$. Для забезпечення функціональної стійкості SDN на основі управління трафіком розглядається скалярна випадкова функція $T_1(e)$, що визначає час до першого перетину процесом $E(t)$ обмежуючої поверхні, заданої вектором обмежень e . На рис. 1 наведено приклад визначення часу T для параметра трафіку у вигляді скалярного процесу $E(t)$ з обмеженнями $E_0 = [a, b]$.




Рис. 1. Визначення часу нормального (штатного) функціонування SDN

Визначивши залишок часу перебування параметрів SDN у допустимій області як $\Delta T = T - t_k$, правило нормальної роботи SDN (4) можна звести до скалярної задачі пошуку $\Delta T_\omega > \theta$, що суттєво спрощує її рішення.

Водночас, через різні контрольні інтервали θ та різні умови експлуатації на підприємствах виникає потреба індивідуального прогнозування параметрів трафіку, щоб запобігти їх виходу за допустимі межі.

5. Метод прогнозу індивідуальної траєкторії параметрів трафіку на основі машинного навчання

AR-моделі для прогнозування трафіку в SDN. З існуючих методів машинного навчання для прогнозування трафіку в SDN часто використовують статистичні методи на основі авторегресійного аналізу (AR). Дані для таких моделей формуються у вигляді часового ряду – послідовності значень параметра трафіку за часом. Як метрики зазвичай беруть обсяг переданих пакетів або байтів, швидкість потоку, затримку, втрати пакетів або завантаження каналів; ці дані можна отримати через OpenFlow або системи моніторингу, такі як sFlow чи NetFlow.

Дані збирають у певних часових інтервалах – секундах, хвилинах чи годинах, підраховуючи сумарний обсяг трафіку або середнє значення параметра. У результаті формується часовий ряд, де кожне значення відповідає параметру трафіку в конкретний момент часу:

$$X = (x_1, x_2, \dots, x_t). \quad (5)$$

Перед використанням у моделі дані нормалізують, заповнюють пропуски та виділяють сезонні коливання, наприклад денні цикли. Моделі ARMA та ARIMA прогнозують значення на основі попередніх даних і похибок, а SARMA та SARIMA враховують сезонні коливання, що характерні для мережевого трафіку.

Задача прогнозування трафіку в SDN полягає в індивідуальному передбаченні параметрів у вузлах мережі, починаючи від конкретної траєкторії параметра. Вхідними даними слугують контролю трафіку, що формують вектор параметрів $X = (X_1, X_2, \dots, X_H)$ для AR-моделей. Для нього визначають область допуску S_0 , де виконання умови $X \in S_0$ відповідає нормальній роботі SDN. Параметри SDN у часі описує випадковий процес $X(t)$, статистично визначений на часовій осі при $t \geq t_1$, де t_1 – початок спостережень.

Для конкретного вузла SDN ω момент контролю $t_k \geq t_1$ визначає проміжок $x_\omega(t) \in S_0, t_1 \leq t \leq t_k$ реалізації процесу $X(t)$, який отримують із даних контролю трафіку. Тоді індивідуальне прогнозування зводиться до визначення умовного закону розподілу часу виходу процесу $X(t)$ за межі допуску S_0 відносно щодо даної реалізації $x_\omega(t)$, тобто до обчислення відповідної ймовірності

$$P^{ps}(s) = P\{X(s) \in S_0 / x_\omega(t), t_1 \leq t \leq t_k, s \geq t_k\}. \quad (6)$$

Рівняння (6) задає умовну ймовірність того, що трафік вузла SDN ω до моменту $s > t_k$ не вийде за межі допуску, враховуючи попередню реалізацію $x_\omega(t), t_1 \leq t \leq t_k$. Це дозволяє виконати індивідуальне прогнозування трафіку вузла ω .

Хоча така постановка спрощена і не враховує похибок контролю, вона є базою для прогнозу. Реальні процеси в SDN складні через різноманітне обладнання та численні фактори, але їхні випадкові процеси мають спільні ознаки: нестационарність, післядію, багатовимірність і взаємозв'язок параметрів трафіку. Це дозволяє застосовувати аналітичні та статистичні методи. Класичні AR-методи дають лише точкові оцінки в окремі моменти $s > t_k$ і не вирішують повну задачу прогнозування (6). Тому для індивідуального прогнозу краще використовувати метод за наступною схемою:

1. Формування аналітичного опису процесу $X(t)$.
2. Розробка алгоритму з урахуванням конкретної реалізації $x_\omega(t), t_1 \leq t \leq t_k$ та побудова оновленого процесу $X^{ps}(s), s > t_k$.
3. Формування множини реалізацій оновленого процесу $X^{ps}(s), s > t_k$ та отримання його характеристик.

Універсальний метод може базуватися на часових поліномах із випадковими коефіцієнтами [12, 13], але більш доцільним є підхід через розкладання процесу трафіку у вигляді:

$$X(t) = m(t) + \sum_v V_v \phi_v(t), \quad (7)$$

де $m(t)$ – математичне очікування процесу; $\phi_v(t)$ – координатні (невипадкові) функції часу; V_v – випадкові, ортогональні коефіцієнти з параметрами $M[V_v] = 0$, $M[V_v, V_\mu] = 0$, $v \neq \mu$.

Розкладання, використане в роботі [14], довело свою ефективність для будь-якого випадкового процесу, що корисно для аналізу трафіку SDN. Відмінність між підходами [15] та [12] полягає у способі оптимізації: у [15] мінімізується середньоквадратична похибка на всьому інтервалі, а у [12] – у кожній точці окремо. Тому розкладання [12] більш практичне для прогнозування першого перетину граничного значення трафіку [16].

У контексті машинного навчання параметри трафіку SDN розглядають як часові ряди. На їх основі будують базову модель, що описує статистику трафіку, яка згодом уточнюється новими даними,

формує *оновлену модель* для прогнозування. Для глибшого аналізу структури трафіку доцільно застосувати розкладання Карунена-Лоева, що виділяє ортогональні компоненти та спрощує прогнозний аналіз.

Розкладання базового випадкового процесу за схемою Карунена-Лоева. Вираз (7) подає випадковий процес у вигляді розкладання Карунена-Лоева, описаного в роботах [15, 17]. Розглянемо основні властивості цього розкладання для оцінки його придатності до моделювання трафіку SDN.

Нехай скалярний випадковий процес $X(t)$ задано послідовністю значень $X(t_i) = X(i), i = \overline{1, I}$ на дискретному ряді спостережень t_i . Тоді розкладання Карунена-Лоева має вигляд:

$$X(i) = m(i) + \sum_{v=1}^i V_v \phi_v(i), i = \overline{1, I}, \quad (8)$$

де V_v – випадковий коефіцієнт з математичним очікуванням $M[V_v] = 0$, $M[V_v, V_\mu] = 0$, $v \neq \mu$; та дисперсією $M[V_v^2] = D_v$; $\phi_v(i)$ – не випадкова координатна функція, $\phi_v(v) = 1$, $\phi_v(i) = 0$ при $v > i$.

Дисперсію та кореляційну функцію для цього розкладання можна записати як:

$$D(i) = \sum_{v=1}^i D_v \phi_v^2(i), i = \overline{1, I}, \quad (9)$$

$$D(i, j) = \sum_{v=1}^{\inf(i, j)} D_v \phi_v(i) \phi_v(j), i, j = \overline{1, I}. \quad (10)$$

Як зазначено в [12], оптимальні властивості розкладання Карунена-Лоева досягаються, якщо його елементи задаються рекурентними співвідношеннями:

$$V_1 = \overset{\circ}{X}(1), V_i = \overset{\circ}{X}(i) - \sum_{v=1}^{i-1} V_v \phi_v(i), i = \overline{2, I}; \quad (11)$$

$$D_1 = D(1), D_i = D(i) - \sum_{v=1}^{i-1} D_v \phi_v^2(i), i = \overline{2, I}; \quad (12)$$

$$\phi_v(i) = \frac{1}{D_v} M[V_v \overset{\circ}{X}(i)], v = \overline{1, I}, i = \overline{v, I}. \quad (13)$$

Отже, вираз (8) застосовний як для скалярного процесу, так і для процесу з залежними складовими. Єдиною вимогою для застосування методу є скінченність дисперсії, що виконується для реальних процесів контролю трафіку SDN, забезпечуючи універсальність методу Карунена-Лоева. Вираз (8) точно визначає процес у точках спостереження і мінімізує середньоквадратичну похибку між ними [12, 14, 16, 17]. Таким чином, розкладання Карунена-Лоева дозволяє ефективно вирішувати задачу прогнозування трафіку (6).

5. Порівняння розробленого методу з класичними авторегресійними методами

Достовірність методу підтверджується моделюванням (рис. 2–7), де на основі статистики трафіку прогнозуються індивідуальні траєкторії завантаженості вузла SDN за розкладанням Карунена-Лоева.

На рис. 2 показано базовий процес спостереження за трафіком вузла протягом 60 хв ранкового періоду. Параметром контролю обрано завантаженість вузла (% від максимальної продуктивності). У певні проміжки окремі дні досягають критичного рівня 85%, що викликає затримки у передачі пакетів та потребує втручання контролера для перерозподілу навантаження.




Рис. 2. Базовий процес трафіку вузла SDN

Для контрольної траєкторії обрано реалізацію, яка після 48 хв потрапляє у контрольовану зону $\geq 85\%$ (рис. 3), з якою порівнюватимуться прогнозні траєкторії. Для наочності розглядається проміжок часу з 30 хв, а середнє значення базового процесу позначено для оцінки загальної тенденції трафіку. Це дозволяє оцінити точність різних методів прогнозування у відтворенні реальної поведінки трафіку вузла SDN. Такий підхід дає змогу порівнювати ефективність класичних AR-моделей, методів ковзного середнього та розкладання Карунена-Лоева у відтворенні як тренду, так і короткочасних коливань трафіку.






Рис. 3. Математичне очікування базового процесу та контрольна траєкторія (підозрілий процес)


Вибравши за початок спостережень момент $t_1 = 30$ хв задаємо значення t_k , кратні 10 с. На рис. 4 видно, що при $t_k = 30$ с, коли вже є 3 спостереження (без початкового стану при $t_1 = 30$ хв), різні методи прогнозування дають різні траєкторії. Найбільш наближеними до контрольного процесу є прогнози за математичним очікуванням (МО) та ковзним середнім (МА). Прогноз за розкладанням Карунена-Лоева (KLE) загалом відтворює тенденцію, хоча з відхиленнями. Інші методи здебільшого відтворюють лише середнє, не враховуючи тренд. SARIMA на цьому етапі не працює через недостатність статистики, а FARIMA не відтворює суть процесу, спираючись лише на перші значення.

Рис. 4. Результати прогнозування ($t_k = 30$ с)


Збільшення часу $t_k = 300$ с (рис. 5) дозволяє запрацювати SARIMA та трохи знизити похибку FARIMA. Методи SARIMA, ARMA, ARIMA та SARMA базуються на середньому базового процесу, майже не враховуючи його тенденцію та розкид. Натомість KLE відтворює контрольну траєкторію майже повністю, за винятком окремих викидів, для яких 30 спостережень виявилось недостатньо.

Рис. 5. Результати прогнозування ($t_k = 300$ с)

Збільшення часу спостережень до $t_k = 600$ с (рис. 6) активує SARIMA, яка відтворює загальну динаміку, але з недостатньою точністю. Прогноз KLE майже повністю збігається з контрольним процесом, демонструючи високий потенціал методу, зокрема для пікових навантажень.

Рис. 6. Результати прогнозування ($t_k = 600$ с)

Подальше збільшення часу спостережень (рис. 7) ще більше підтверджує точність KLE, тоді як інші методи суттєво не покращуються.

Рис. 7. Результати прогнозування ($t_k = 1080$ с)

Аналіз результатів моделювання (рис. 2–7) показує, що лише прогнозування за математичним очікуванням (МО) та SARIMA забезпечує достатню деталізацію на всьому діапазоні прогнозу, хоча SARIMA потребує накопичення початкових даних. Інші методи, зокрема ковзне середнє (MA), залежать від загального середнього і придатні лише для стаціонарних процесів без вираженої сезонності та тренду.

Порівняння точності прогнозу за розкладанням Карунена-Лоева (KLE) з іншими методами демонструє ефективність удосконаленого підходу для прогнозування трафіку SDN (табл. 1), оцінюваного за нормалізованою середньоквадратичною похибкою

$$\text{NRMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - z_i)^2} / (\max(z) - \min(z)).$$

Таблиця 1

Порівняння різних методів прогнозу трафіку за NRMSE, %

№	Метод	Час контролю t_k , с										
		30	60	120	180	240	360	480	600	720	840	1080
1.	MO	23.1	23.3	23.5	23.7	24.0	28.2	31.6	31.4	35.7	38.9	45.7
2.	MA	29.9	29.1	28.9	28.4	27.4	27.9	28.7	28.7	24.1	29.3	35.5
3.	AR	29.6	28.8	28.6	27.7	26.3	26.3	27.8	28.2	23.8	26.4	33.8
4.	ARMA	29.7	28.8	28.5	27.7	26.3	26.3	27.5	28.2	23.4	26.2	33.7
5.	ARIMA	28.9	30.1	35.6	34.6	30.6	29.4	24.3	25.5	21.5	25.4	39.2
6.	SARMA	30.2	29.4	29.9	28.9	27.4	28.4	28.5	29.7	25.1	27.1	32.9
7.	SARIMA	29.7	28.9	28.7	27.8	26.4	25.5	27.2	23.6	22.2	24.5	33.7
8.	FARIMA	$+\infty$	1426	1249	387	194	94.5	69.7	47.2	42.0	38.6	40.3
9.	KLE	15.6	13.9	6.7	5.1	5.2	2.2	1.2	0.5	0.3	0.1	0.0

Як видно з табл. 1, класичні методи прогнозування часових рядів (MO, MA, AR, ARMA, ARIMA, SARMA, SARIMA) показують відносно високе середнє відхилення (NRMSE 23–40%) через недостатнє врахування нелінійності та стохастичного характеру трафіку SDN. Особливо слабкими виявилися методи для коротких інтервалів, оскільки різкі сплески трафіку погано апроксимуються лінійними моделями. FARIMA демонструє нестабільність і на малих періодах дає аномально великі помилки, що обмежує його практичне застосування.

Натомість розкладання Карунена-Лоева (KLE) показало значно кращі результати: при спостереженнях понад 120 с відхилення зменшується до одиниць відсотків, а при 840–1080 с майже до нуля. Це пояснюється здатністю KLE виділяти базові компоненти процесу та відтворювати динаміку трафіку навіть при високій варіативності. Таким чином, традиційні методи слабкі через невідповідність складним стохастичним характеристикам SDN-трафіку, тоді як спектрально-статистичні методи, як KLE, виявляються найбільш ефективними.

6. Висновки

На основі проведеного дослідження можна зробити основні висновки щодо прогнозування параметрів трафіку в програмно-керованих мережах (SDN) з метою забезпечення їх функціональної стійкості.

1. Класичні методи прогнозування часових рядів (MO, MA, AR, ARMA, ARIMA, SARMA, SARIMA) показують обмежену ефективність через недостатнє врахування нелінійності та стохастичного характеру трафіку SDN. Вони особливо слабкі на коротких інтервалах спостережень, де різкі сплески навантаження не піддаються точній апроксимації, а метод FARIMA виявляє високу нестабільність, що обмежує його практичне застосування.

2. Метод розкладання за схемою Карунена-Лоева (KLE) демонструє значно кращі результати, забезпечуючи точне відтворення траєкторії трафіку навіть при високій варіативності та пікових навантаженнях. Уже при періодах спостережень понад 120 с точність прогнозу зростає (відхилення в межах одиниць відсотків), а при 840–1080 с відхилення практично зводиться до нуля. Це свідчить про високу придатність KLE для індивідуального прогнозування параметрів трафіку в SDN та можливість ефективного управління потоками даних у реальному часі.

Таким чином, результати дослідження підтверджують, що для сучасних програмно-керованих мереж оптимальним підходом до прогнозування параметрів трафіку є спектрально-статистичні методи, які враховують стохастичні та нелінійні характеристики процесів. Використання KLE дозволяє підвищити функціональну стійкість SDN, забезпечуючи передбачувану якість обслуговування та зменшуючи ризик перевантажень і затримок у передачі пакетів.

Список використаної літератури

1. Кравченко, Ю. В., Фісун, О. С. (2025). Аналіз існуючих методів забезпечення функціональної стійкості складних систем для удосконалення комп'ютерних мереж. Зв'язок, № 3, 29–35. <https://doi.org/10.31673/2412-9070.2025.025385>
2. Asten, B. J., Adrichem, N. L. M., Kuipers, F. A. (2014). Scalability and Resilience of Software-Defined Networking: An Overview. arXiv:1408.6760, 18 p. <https://doi.org/10.48550/arXiv.1408.6760>
3. Chhaytli, A., Persikov, M. (2021). Providing cyber resilience in software-defined networks by secure routing means. Infocommunication Technologies and Electronic Engineering. Lviv Politechnic Publishing House, 1(1), 11–19. URL: <https://ena.lpnu.ua:8443/server/api/core/bitstreams/ec63a178-08ed-4c54-affc-8d0a6b6d8913/content>

4. Josbert, N. N., Ping, W., Wei, M., & Li, Y. (2021). Industrial Networks Driven by SDN Technology for Dynamic Fast Resilience. *Information*, 12(10), 420. <https://doi.org/10.3390/info12100420>
5. Grammatikis, P. R., Sarigiannidis, P., Dalamagkas, et al. (2021). SDN-Based Resilient Smart Grid: The SDN-microSENSE Architecture. *Digital*, 1(4), 173-187. <https://doi.org/10.3390/digital1040013>
6. Akinola, O. I., Olaniyi, O. O., Ogungbemi, O. S., Oladoyinbo, O. B., and Olisa, A. O. (2024). Resilience and Recovery Mechanisms for Software-Defined Networking (SDN) and Cloud Networks. *Journal of Engineering Research and Reports*, 26(8), 112–134. <https://doi.org/10.9734/jerr/2024/v26i81234>
7. Rehman, A., Aguiar, R., Barraca, J. P. (2019). Fault-Tolerance in the Scope of Software-Defined Networking (SDN). *IEEE Access*, 7, 1, 124474–124490. DOI: <https://doi.org/10.1109/ACCESS.2019.2939115>
8. Sharma, A., Balasubramanian, V., & Kamruzzaman, J. (2023). A Novel Dynamic Software-Defined Networking Approach to Neutralize Traffic Burst. *Computers*, 12(7), 131. <https://doi.org/10.3390/computers12070131>
9. Khan, T. U., Markarian, C., Fachkha, C. (2023). Stability analysis of new generalized mean-square stochastic fractional differential equations and their applications in technology. *AIMS Mathematics*, 8(11), 27840–27856. <https://doi.org/10.3934/math.20231424>
10. Chesi, G. (2024). LMI-Based Robustness Analysis In Uncertain Systems. *Foundations and Trends in Systems and Control*, 11, 1–2. <https://doi.org/10.1561/26000000030>
11. Барабаш, О. В. (2004). Побудова функціонально стійких розподілених інформаційних систем. Монографія. Київ: НАОУ. 226 с. URL: <https://www.dropbox.com/scl/fi/zxcdkzd7s5ao05x45uzz5/Barabash-O.-Construction-of-functionally-stable-distributed-information-systems.pdf?rlkey=dfonzkwr9zqjrsob73823f0rk&dl=>
12. Кудрицький, В. Д. (1982). Прогнозуючий контроль радіоелектронних пристроїв. К.: Техніка. 168 с.
13. Nagorny, V., Lavrov, E., Chybiriak, Y. (2019). Forecasting individual resource of technical systems. *Radio Electronics, Computer Science, Control*. <https://doi.org/10.15588/1607-3274-2019-1-5>
14. Savchenko, V., Matsko, O., Vorobiov, O., Kizyak, Y., Kriuchkova, L., Tikhonov, Y., & Kotenko, A. (2018). Network traffic forecasting based on the canonical expansion of a random process. *Eastern-European Journal of Enterprise Technologies*, 3(2 (93), 33–41. <https://doi.org/10.15587/1729-4061.2018.131471>
15. Zhu, B. & Hiraishi, T. (2023). A decomposed Karhunen-Loève expansion scheme for the discretization of multidimensional random fields in geotechnical variability analysis. *Stochastic Environmental Research and Risk Assessment*, 37(4), 1215–1233. <https://doi.org/10.1007/s00477-023-02625-8>
16. Atamanyuk, I., Kondratenko, Y., Zavgorodnii, A., Lugovoy, S., Lykhach V., and Kramarenko, S. (2021). Multiparameter Stochastic Control Model Based on the Random Sequence Canonical Expansion. 2021 IEEE 12th International Conference on Electronics and Information Technologies (ELIT), Lviv, Ukraine, 291–296. <https://doi.org/10.1109/ELIT53502.2021.9501146>
17. Shebanin, V., Atamanyuk, I., Kondratenko, Y. (2020). Synthesis of Control Systems on the Basis of a Canonical Vector Decomposition of Random Sequences. *Proceedings of 25th IEEE International Conference on Problems Of Automated Electric Drive*, 21–25 September, Kremenchuk, Ukraine. <https://doi.org/10.1109/PAEP49887.2020.9240808>