

<https://doi.org/10.21869/2223-1536-2026-16-2-76-90>



УДК 004.9

Обнаружение и классификация перегрузок многомашинных вычислительных систем

Ю. С. Бехтин¹, К. С. Баланев¹, А. В. Титова² ✉

¹ Национальный исследовательский университет «МЭИ»
ул. Красноказарменная, д. 14/1, г. Москва 111250, Российская Федерация

² Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: nyatarr@yandex.ru

Резюме

Цель исследования – разработать критерии обнаружения и классификации перегрузок, возникающих в многомашинных вычислительных системах, по данным сетевого трафика с опорой на анализ его регулярного тренда и последующую вероятностную интерпретацию перегрузочного состояния.

Методы. В качестве метода выделения регулярного тренда сетевого трафика используется вейвлет-регрессионная обработка временного ряда, обеспечивающая подавление высокочастотных возмущений и сохранение регулярной составляющей. Для выявления интервалов перегрузки применяется байесовский обнаружитель импульсных сигналов, формирующий сглаженную импульсную последовательность апостериорных вероятностей превышения нормального режима. Для количественного описания каждого перегрузочного эпизода введена параметрическая модель импульса на основе гауссовой аппроксимации, позволяющая связать перегрузку с тремя измеримыми характеристиками: амплитудой, длительностью и интегральной площадью. Дополнительно предложены нормализованные показатели параметров относительно статистики нормального режима и интегральный критерий отклонения, обеспечивающий оценку выраженности перегрузочного состояния.

Результаты. Получены критерии и правила классификации перегрузок по пяти типам: импульсная, фоновая, прогрессирующая, периодическая и атакующая. Результаты имитационного моделирования на данных с различными режимами нагрузки показали работоспособность предложенного подхода: перегрузочные эпизоды выделяются устойчиво, а типизация соответствует ожидаемой структуре сценариев. Выявлены особенности реакции вероятностного обнаружителя на плавно нарастающую нагрузку, способную проявляться как последовательность локальных импульсов.

Заключение. Разработанная методика обеспечивает переход от визуальной интерпретации выходного сигнала байесовского обнаружителя к количественной оценке и типизации перегрузок и может применяться в задачах автоматизированного мониторинга сетевого трафика и поддержки решений по управлению качеством обслуживания в многомашинных вычислительных системах.

Ключевые слова: сетевой трафик; перегрузка; вейвлет-регрессия; вероятностное реле; критерии классификации; апостериорная вероятность; классификация аномалий.

Финансирование: Данная работа финансировалась за счет средств бюджета в рамках государственного задания Министерства науки и высшего образования РФ № FSWF-2025-0010 «Разработка научно-технических основ создания программных и аппаратных решений для управления объектами энергетики с использованием цифровых двойников и технологий искусственного интеллекта».

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Бехтин Ю. С., Баланев К. С., Титова А. В. Обнаружение и классификация перегрузок многомашинных вычислительных систем // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 76–90. <https://doi.org/10.21869/2223-1536-2026-16-2-76-90>.

Поступила в редакцию 02.04.2026

Подписана в печать 01.05.2026

Опубликована 30.06.2026

Detection and classification of network congestions in multi-machine computing systems

Yuri S. Bekhtin¹, Kirill S. Balanov¹, Anna V. Titova² ✉

¹ National Research University "Moscow Power Engineering Institute"
14/1 Krasnokazarmennaya Str., Moscow 111250, Russian Federation

² Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: nyatarr@yandex.ru

Abstract

The purpose of the research is to develop criteria for detecting and classifying overloads occurring in multi-machine computing systems based on network traffic data based on an analysis of its regular trend and subsequent probabilistic interpretation of the overload state.

Methods. The wavelet regression processing of the time series is used as a method for detecting the regular trend of network traffic, which ensures the suppression of high-frequency disturbances and the preservation of the regular component. To identify overload intervals, a Bayesian pulse signal detector is used, which generates a smoothed pulse sequence of a posteriori probabilities of exceeding the normal mode. To quantify each overload episode, a parametric pulse model based on Gaussian approximation is introduced, which makes it possible to associate overload with three measurable characteristics: amplitude, duration, and integral area. Additionally, normalized parameter indicators relative to normal mode statistics and an integral deviation criterion are proposed, which provides an assessment of the severity of the overload condition.

Results. Criteria and rules for classifying overloads into five types are obtained: impulse, background, progressive, periodic and attacking. The results of simulation modeling on data with different load modes showed the efficiency of the proposed approach: overload episodes are consistently highlighted, and the typing corresponds to the expected structure of scenarios. The features of the probabilistic detector's response to a smoothly increasing load, which can manifest itself as a sequence of local pulses, are revealed.

Conclusion. The developed technique provides a transition from visual interpretation of the Bayesian detector output signal to quantification and typification of congestion and can be used in tasks of automated monitoring of network traffic and support for quality-of-service management solutions in multi-machine computing systems.

Keywords: network traffic; overload; wavelet regression; probabilistic relay; classification criteria; posterior probability; anomaly classification.

Funding: This work was financed from the budget within the framework of the state task of the Ministry of Science and Higher Education of the Russian Federation No. FSWF-2025-0010 "Development of scientific and technical foundations for creating software and hardware solutions for managing energy facilities using digital twins and artificial intelligence technologies".

Conflict of interest: The Authors declares the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Bekhtin Y.S., Balanov K.S., Titova A.V. Detection and classification of network congestions in multi-machine computing systems. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(2):76-90. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-76-90>.

Received 02.04.2026

Accepted 01.05.2026

Published 30.06.2026

Введение

Проблема обнаружения и классификации перегрузок многомашинных вычислительных систем (МВС) сохраняет свою актуальность на фоне роста объёмов данных и усложнения архитектуры распределённых сетей. Перегрузка МВС, как, впрочем, и любой компьютерной сети, проявляется в виде изменения интенсивности транзакций, роста задержек и увеличения вероятности потерь пакетов, что приводит к деградации качества обслуживания и снижению устойчивости МВС. Очевидно, мониторинг сетевого трафика МВС в реальном масштабе времени теоретически позволяет не только выявлять факты перегрузки, но количественно и качественно оценивать её выраженность. Однако применяемые в настоящее время на практике известные методы обнаружения перегрузок, которые можно условно разделить на несколько классов, не являются в достаточной степени эффективными.

К числу основных методов относятся алгоритмы управления сетевыми очередями, такие как Random Early Detection (RED), использующие вероятностный сброс пакетов при превышении порогов средней длины очереди [1]. Развитие этого направления привело к появлению модифицированных версий RED, например Adaptive Dual RED (AD-RED), где вероятностная функция сброса формируется на основе комби-

нации квадратичного и экспоненциального законов [2]. Параллельно развивается линия исследований, посвящённых применению методов машинного обучения для активного управления очередями, что позволяет строить адаптивные модели регулирования, согласованные с динамикой трафика [3].

На транспортном уровне перегрузки фиксируются конечными детекторами TCP, основанными на потерях пакетов (TCP Reno, Cubic) или задержках (TCP Vegas, FAST), что позволяет регулировать скорость передачи, однако в таком случае перегрузка фиксируется с опозданием [4]. Сравнительные исследования показывают, что взаимодействие различных алгоритмов TCP с AQM-механизмами (включая RED, CoDel и их модификации) остаётся предметом активного изучения, в т. ч. в условиях высокоскоростных сетей [5].

Другой широко применяемый класс методов связан с использованием статистического контроля процесса (Statistical Process Control, SPC), включая карты Шухарта, кумулятивные суммы (CUSUM) и экспоненциально взвешенные скользящие средние (EWMA). Эти подходы позволяют строить контрольные границы для временных рядов сетевого трафика и выявлять отклонения от нормального режима [6]. Развитие данного направления связано с сочетанием классических статистических методов и нейросетевых моделей, например в комбинированных алгоритмах

CUSUM, где традиционная статистика дополняется прогнозирующими компонентами, обученными на больших массивах сетевых данных [7].

В последние годы внимание исследователей сосредоточено на вероятностных методах обнаружения изменений параметров временных рядов, включая Bayesian Online Change Point Detection (BOCPD), Page-Hinkley и Generalized Likelihood Ratio (GLR). Эти алгоритмы позволяют выявлять структурные изменения и формировать динамические пороговые значения, что делает их более адаптивными к изменчивой нагрузке [8]. Появились и новые вариации BOCPD, использующие авторегрессионные модели и байесовскую фильтрацию для повышения точности онлайн-детекции [9], а также методы обнаружения изменений в сетевых процессах с пропусками данных, что делает их применимыми к телеметрическим системам [10].

Таким образом, существующие методы анализа сетевого трафика демонстрируют разнообразные подходы к предварительному обнаружению перегрузок, формируя при этом набор эмпирических и статистически обоснованных критериев. Эти результаты создают основу для разработки собственных критериев, согласованных с вейвлет-регрессионным методом [11] и вероятностным реле (байесовский обнаружитель), где перегрузка проявляется в виде импульсной последовательности. Таким образом, задача настоящего исследования заключается не в замещении существующих решений, а в адаптации их принципов к особенностям предложенного метода, что обеспечивает возможность формализованной классификации перегрузочных состояний по

предлагаемому авторами методу. В задачу исследования входит систематизация существующих подходов, определение параметров сетевого трафика и формализация критериев, позволяющих классифицировать различные виды перегрузок сети.

Цель исследования заключается в разработке формализованных критериев обнаружения и классификации перегрузок в многомашинных вычислительных системах на основе анализа временных рядов сетевого трафика и вероятностной интерпретации перегрузочного состояния.

Для достижения поставленной цели в работе решаются следующие задачи:

- выделение регулярной составляющей сетевого трафика при подавлении высокочастотных возмущений;
- формирование вероятностного индикатора перегрузки на основе байесовского обнаружения изменений;
- параметризация перегрузочных эпизодов по амплитудно-временным характеристикам;
- разработка критериев и правил классификации перегрузок по характеру их проявления в сетевом трафике;
- экспериментальная проверка работоспособности предложенного подхода на смоделированных данных.

Материалы и методы

В ранее выполненных исследованиях авторами была предложена методика анализа сетевого трафика, основанная на применении регрессионного анализа в вейвлет-области [12]. Основная идея заключалась в применении стационарного вейвлет-преобразования (Stationary Wavelet Transform, SWT) для выделения трендовой компоненты временного ряда интенсивности тра-

фика и подавления высокочастотных возмущений. На первом этапе исходный временной ряд $x(t)$ (рис. 1), представляющий данные о сетевой нагрузке (это может быть как количество запросов, так и скорость передачи данных, выполняемых в определенный промежуток времени), подвергался многоуровневой вейвлет-декомпозиции до глубины $L = 3$. Для каждого уровня декомпозиции вычислялись коэффициенты аппроксимации A_L и детализации

D_i , где $i = 1, 2, 3$. Полученные коэффициенты детализации аппроксимировались полиномиальными функциями третьей степени по методу наименьших квадратов, что позволило сгладить локальные всплески в деталях. Обратное преобразование (Inverse SWT) восстанавливало трендовую компоненту $\tilde{x}(t)$, характеризующую поведение сетевой нагрузки при устранении случайных выбросов и высокочастотных шумов (см. рис. 1).




Рис. 1. Работа вейвлет-регрессионного метода

Fig. 1. Operation of the wavelet regression method

Дальнейший этап обработки заключался в подаче восстановленного тренда $\tilde{x}(t)$ на вход вероятностного реле, представляющего собой байесовской обнаружитель импульсных сигналов. Вероятностное реле функционировало как нелинейный оператор адаптивного усиления, вычисляя для каждой

точки сигнала апостериорную вероятность перегрузочного состояния. Усиление выполнялось в зависимости от степени отклонения текущего значения тренда от априорного распределения нормального режима и от вероятности перехода системы в перегруженное состояние (см. рис. 1). Таким образом, ве-

роятностное реле выполняло роль динамического фильтра, который выделял участки сигнала с высокой вероятностью перегрузки.

В результате применения данного механизма исходный тренд преобразуется в импульсную последовательность – гладкую во времени функцию $p(t)$, интерпретируемую как апостериорную вероятность перегрузочного состояния. По определению вероятности $0 \leq p(t) \leq 1$; следовательно, амплитуда каждого импульса

$$A = \max_{t \in [t_1, t_2]} p(t) \quad (1)$$

и ограничена сверху единицей ($A \leq 1$). Чем ближе A к 1, тем выше степень уверенности в перегрузке в соответствующий момент времени; при этом амплитуды, близкие к 0, отражают нормальный режим. Визуальный анализ $p(t)$ позволяет различать периоды нормальной работы и перегрузки, однако наличие численных параметров импульсов, как амплитуда $A \in [0, 1]$, длительность $\Delta t = t_2 - t_1$ и интегральная площадь

$$S = \int_{t_1}^{t_2} p(t) dt, \quad (2)$$

позволяет разработать систему критериев, которая позволит на основе этих параметров оценивать степень и вид перегрузки МВС.

Разработка критериев оценки перегрузок для метода вейвлет-регрессии с вероятностным реле

Метод вейвлет-регрессии [13] с последующим применением вероятностного реле позволяет выделять участки сетевого трафика, соответствующие потенциальным перегрузочным состояни-

ям. На выходе реле формируется импульсная последовательность [14] – сглаженный сигнал с локализованными пиками, отражающими высокую апостериорную вероятность превышения нормального режима. Несмотря на хорошую визуальную интерпретируемость, дальнейшее применение метода в автоматизированных системах требует перехода от качественного описания к количественной классификации перегрузок.

В отличие от физических процессов, где амплитуда импульса может служить прямым показателем интенсивности события, в предлагаемом методе величина пиков ограничена значениями вероятности. Апостериорная вероятность, формируемая реле, по определению не превышает 1 и в типичных случаях варьируется в диапазоне 0,2–0,95. Следовательно, при разработке критериев оценки необходимо использовать нормализованные характеристики импульсов, совместимые с вероятностной природой выходного сигнала.

Основной задачей настоящего раздела является формализация параметров выходной импульсной последовательности, обеспечивающая методику для оценки степени, длительности и характера перегрузки. Задача решается на основе методов статистического контроля процессов [15], вероятностной детекции изменений [16] и параметрического моделирования [17], что позволяет обосновать выбор пороговых значений и гарантировать согласованность методологии с общепринятыми средствами анализа сетевых аномалий.

Для формализации импульсов на выходе вероятностного реле целесообразно использовать параметрическую аппроксимацию. Анализируя форму выходных пиков, можно заключить, что

наибольшее соответствие наблюдаемым кривым демонстрирует гауссова модель, обладающая хорошей локализацией во времени и симметричной формой. Такая аппроксимация ранее применялась в задачах анализа агрегированных сетевых аномалий [18] и обеспечивает аналитическую трактовку параметров, отражающих характеристики перегрузки.

Импульс $I(t)$ приближён функцией нормального распределения:

$$I(t) = A \cdot \exp\left(-\frac{(t-t_0)^2}{2\sigma^2}\right), \quad (3)$$

где $A \in (0,1]$ – амплитуда, соответствующая максимальной апостериорной вероятности перегрузочного состояния; t_0 – момент времени максимальной интенсивности; σ – дисперсия, определяющая длительность импульса.

Ширина импульса Δt на уровне половины амплитуды определяется как

$$\Delta t = 2\sqrt{2 \ln 2} \cdot \sigma, \quad (4)$$

а интегральная площадь S под кривой

$$S = \int_{-\infty}^{\infty} I(t) dt \approx A \cdot \sigma \cdot \sqrt{2\pi}. \quad (5)$$

Поскольку амплитуда A ограничена сверху значением 1 (по определению вероятности), следует отказаться от традиционной трактовки A как интенсивности в абсолютных величинах. Вместо этого предлагается рассматривать нормализованные значения амплитуды относительно порога обнаружения перегрузки.

В качестве порогового значения амплитуды предлагается использовать уровень τ_{hi} , который соответствует высокой степени уверенности в перегрузочном состоянии. Такой выбор согласуется с практикой применения байесовских методов обнаружения измене-

ний во временных рядах [19], где значения апостериорной вероятности выше 0,8 рассматриваются как свидетельство существенного отклонения от нормального режима. Кроме того, эмпирические наблюдения показали, что в нормальных условиях уровень пиков редко превышает 0,6, в то время как в периоды перегрузки наблюдаются устойчивые превышения 0,8–0,9.

Оставшиеся параметры импульса – длительность Δt и площадь S – нормализуются по отношению к статистике нормального режима. Для нормализации предварительно вычисляются средние значения и стандартные отклонения параметров по выборке интервалов, классифицированных как нормальные по амплитуде ($A < 0,5$):

$$z_{\Delta t} = \frac{\Delta t - \mu_{\Delta t}}{\sigma_{\Delta t}}, \quad z_S = \frac{S - \mu_S}{\sigma_S}, \quad (6)$$

где $\mu_{\Delta t}$, μ_S – средние значения; $\sigma_{\Delta t}$, σ_S – стандартные отклонения соответствующих параметров при нормальной работе сети.

Далее определяется интегральный критерий отклонения:

$$K = \sqrt{(z_{\Delta t})^2 + (z_S)^2}. \quad (7)$$

На основе нормализованных параметров импульса и интегрального отклонения K можно выделить пять основных типов перегрузочных состояний (табл. 1), различающихся по форме и динамике проявления в сетевом трафике. Каждый тип соответствует определённому сочетанию амплитудных и временных характеристик импульса и отражает специфическое поведение системы в условиях нагрузки.

Предложенная классификация опирается на логическую интерпретацию выходного сигнала вероятностного ре-

ле, где амплитуда отражает уверенность в перегрузке, длительность характеризует её временное развитие, а площадь – общее воздействие на систему. Классификационные признаки согласованы с подходами, использованными в работах по анализу временных структур трафика и выявлению сетевых аномалий [20].

Использование нормализованных параметров обеспечивает устойчивость классификации к масштабным изменениям в структуре нагрузки, а параметр K служит универсальной метрикой для первичного выделения аномальных состояний. Дальнейшая идентификация вида перегрузки осуществляется на основе анализа формы и структуры импульса в пределах превышения $K > 2,5$,

что согласуется с классической стратегией многоуровневой фильтрации [21].

Результаты и их обсуждение

Для проверки применимости разработанного метода к задаче обнаружения и классификации перегрузок были проведены экспериментальные исследования на смоделированных данных, имитирующих различные режимы работы МВС. Целью эксперимента являлась оценка способности метода выделять перегрузочные состояния с учётом их формы и динамики, а также проверка предложенных критериев классификации на основе параметров импульсной последовательности.

Таблица 1. Классификация типов перегрузок МВС по параметрам импульсной последовательности

Table 1. Classification of MCS overload types by pulse sequence parameters

Тип перегрузки	Амплитуда	Нормализованная длительность	Нормализованная площадь	Дополнительные признаки	Интерпретация
Импульсная	$A \geq 0,8$	$z_{\Delta t} < 1$	$z_S < 1$	Изолированный пик	Кратковременный, но интенсивный перегрузочный всплеск
Фоновая	$0,6 \geq A \geq 0,8$	$z_{\Delta t} \geq 1,5$	$z_S \geq 1,5$	Отсутствие чётких границ, плато-образный участок	Длительное насыщение канала
Прогрессирующая	A растёт во времени	$z_{\Delta t} \uparrow$	$z_S \uparrow$	Серия импульсов с увеличением параметров	Постепенное накопление нагрузки
Периодическая	$A \approx \text{const}$	$z_{\Delta t} \approx \text{const}$	$z_S \approx \text{const}$	Повторение пиков через равные интервалы τ	Циклический характер нагрузки
Атакующая	$A \geq 0,9$	Любое	$z_S \gg 2$	Снижение разнообразия трафика, высокая автокорреляция	Внешнее воздействие (например, DDoS атака)

Смоделированный набор данных (рис. 2) включал чередующиеся участки с различными типами нагрузок, соответствующими основным классам перегрузок: нормальное состояние, импульсная, фоновая, прогрессирующая, периодическая и атакующая перегрузки. Интенсивность трафика в каждом сегменте формировалась с использованием регулируемых стохастических и детерминированных компонентов, отражающих особенности соответствующего режима. Для нормального сегмента использовался слабокоррелированный шум с

постоянным средним значением. Импульсные перегрузки реализовывались в виде резких одиночных всплесков. Фоновые перегрузки моделировались как устойчиво повышенный уровень интенсивности, сохраняющийся длительное время. Прогрессирующая перегрузка была задана в виде монотонно возрастающей функции интенсивности, периодическая – как синусоидальное изменение, а атакующая – как последовательность равномерно распределённых пиков высокой амплитуды и плотности, с пониженной вариативностью.




Рис. 2. Смоделированный набор данных

Fig. 2. The simulated data set

Для обработки тестовых данных применялась методика, описанная в предыдущих разделах: извлечение трендовой компоненты с помощью стацио-

нарного вейвлет-преобразования (рис. 3), подача регулярного тренда на вероятностное реле и последующее формирование импульсной последовательности.




Рис. 3. Выделение регулярного тренда трафика

Fig. 3. Highlighting the regular traffic trend

Каждый обнаруженный пик был аппроксимирован гауссовой функцией и охарактеризован по трём основным параметрам: амплитуде A , длительности Δt и площади S . Для оценки степени отклонения от нормального режима использовались нормализованные значения параметров и интегральный крите-

рий K , построенный по евклидовой норме в пространстве $(z_{\Delta t}, z_S)$.

В результате обработки смоделированного временного ряда были обнаружены 22 перегрузочных импульса. Таблица 2 содержит выборочные сводные данные по результатам проведенного эксперимента.

Таблица 2. Параметры обнаруженных перегрузок и результаты их классификации

Table 2. Parameters of detected overloads and the results of their classification

i	L	R	t_0	Амп- литуда	Ширина импульса	Нормализо- ванная дли- тельность	Нормали- зованная площадь	Тип перегрузки
0	296	298	297	0,65	10	0,50	-1,36	Прогрессирующая
1	362	369	364	0,81	10	0,50	0,56	Импульсная пере- грузка
2	433	439	434	0,78	10	0,50	0,18	Прогрессирующая
3	482	489	484	0,81	11	0,75	0,57	Импульсная пере- грузка
4	775	1013	778	0,79	244	59,00	75,25	Фоновая пере- грузка
.....								
17	2024	2031	2026	0,82	11	0,75	0,64	Атакующая
18	2408	2413	2410	0,69	10	0,50	-0,34	Фоновая пере- грузка
19	2454	2461	2456	0,79	12	1,00	0,57	Прогрессирующая
20	2502	2509	2504	0,80	12	1,00	0,57	Импульсная пере- грузка
21	2551	2555	2552	0,66	10	0,50	-0,73	Фоновая пере- грузка

Результаты визуализированы ниже (рис. 4). График иллюстрирует форму выходного сигнала вероятностного реле

$V(t)$, пороговые уровни τ_{mid} и τ_{hi} , а также классифицированные импульсы с подписями соответствующих типов.




Рис. 4. Визуализация работы вероятностного реле и результатов обнаружения и классификации

Fig. 4. Visualization of the probabilistic relay operation and the results of detection and classification

Анализ классификации показал высокую степень соответствия между обнаруженными импульсами и ожидаемыми типами перегрузок. Тем не менее при сопоставлении с реальной структурой нагрузки были выявлены отдельные расхождения, отражающие особенности работы вероятностного реле.

Наиболее заметное расхождение наблюдалось в сегменте с прогрессирующей перегрузкой [1250–1500], где интенсивность возрастает монотонно. Вероятностное реле в таких случаях реагирует не на общий тренд, а на локальные изменения – точки ускоренного роста или кратковременные скачки, что приводит к разбиению прогрессирующего сегмента на серию отдельных импульсов, каждый из которых классифицируется изолированно. Несмотря на то, что суммарная форма соответствует плавному нарастанию нагрузки, итоговая классификация фиксирует импульсные или фоновые состояния, не отражая факта накопления трафика.

Причины указанных расхождений связаны с конструктивной особенностью вероятностного реле. Оно функционирует как нелинейный усилитель локальных отклонений и имеет повышенную чувствительность к резким из-

менениям. При этом длительные и плавные отклонения от нормы воспринимаются как малозначимые и могут быть отфильтрованы. Таким образом, метод демонстрирует высокую эффективность при обнаружении кратковременных, периодических и атакующих перегрузок, но требует дополнительной адаптации для корректного выявления прогрессирующих перегрузок.

Выводы

В рамках настоящего исследования разработаны формализованные критерии оценки перегрузок сетевого трафика, возникающих в многомашиных вычислительных системах. Критерии основаны на количественной интерпретации выходного сигнала вероятностного реле, представляющего собой последовательность апостериорных вероятностей превышения нормального режима. Аппроксимация импульсных участков гауссовыми функциями позволила осуществить параметризацию каждого перегрузочного состояния по трём измеримым характеристикам – амплитуде, длительности и площади, что обеспечило основу для последующей классификации.

Введена система нормализованных показателей и интегральный критерий

отклонения, устойчивый к масштабным колебаниям трафика.

Разработанная система классификации включает пять основных типов перегрузок, соответствующих характерным сценариям работы МВС. Проведённые эксперименты на смоделированных данных показали высокую согласованность между классификацией и

реальной структурой нагрузки, подтвердив применимость предложенных критериев в условиях изменяющейся сетевой динамики. Полученные результаты могут быть использованы в системах автоматизированного мониторинга и анализа трафика, а также в задачах прогнозирования и адаптивного управления качеством обслуживания.

Список литературы

1. Петушков Г. В. Оценка производительности вычислительной системы // Известия Юго-Западного государственного университета. 2025. Т. 29, № 2. С. 201–220.
2. Hassan S. O. AD-RED: A new variant of random early detection AQM algorithm // Journal of High Speed Networks. 2024. Vol. 30, N 1. P. 53–67.
3. Тоорчинеzhad M. P., Ahmadi M. Machine learning approaches for active queue management: A survey, taxonomy, and future directions // arXiv.org. URL: <https://arxiv.org/abs/2410.02563> (дата обращения: 15.03.2026).
4. Технологии оптимизации сетевого трафика / Д. В. Гадасин, А. Д. Кобелькова, А. А. Родина, М. А. Сурова // Системы синхронизации, формирования и обработки сигналов. 2025. Т. 16, № 3. С. 9–16.
5. Muhammad S., Chaudhery T. J., Noh Y. Study on performance of AQM schemes over TCP variants in different network environments // IET Communications. 2021. N 15. P. 93–111. <https://doi.org/10.1049/cmu2.12061>.
6. Математическое моделирование системы автоматического регулирования численным интегрированием / В. А. Хандожко, О. Н. Федонин, В. П. Матлахов, А. В. Хандожко // Известия Юго-Западного государственного университета. 2025. Т. 29, № 2. С. 55–70.
7. Neural network-based CUSUM for online change-point detection / T. Gong, J. Lee, X. Cheng, Y. Xie // arXiv.org. URL: <https://arxiv.org/abs/2210.17312> (дата обращения: 15.03.2026).
8. Performance measurement of Bayesian online changepoint detection and its application / M. Shimono [et al.] // Second International Conference on Advanced Robotics, Automation Engineering, and Machine Learning (ARAEML 2025). SPIE, 2025. Vol. 13815. P. 83–103.
9. Tsaknaki I.-Y., Lillo F., Mazzarisi P. Bayesian Autoregressive Online Change-Point Detection with Time-Varying Parameters // arXiv.org. URL: <https://arxiv.org/abs/2407.16376> (дата обращения: 15.03.2026).
10. Online Bayesian changepoint detection for network Poisson processes with community structure / J. Corneek [et al.] // Statistics and Computing. 2025. Vol. 35, N 3. P. 1–29.
11. Bekhtin Y. S., Balanev K. S. Simulation Modeling Network Traffic Behavior Using Regression Analysis in Wavelet Domain // 2024 6th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE). Moscow: IEEE, 2024. P. 1–6.

12. Stability Appraisal of the Wavelet-and-Regression Method for Unsteady Network Traffic Trend Highlighting / Y. S. Bekhtin, K. S. Balanov, E. A. Dubrovskaya, A. V. Pavlovich // 2025 7th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE). Moscow: IEEE, 2025. P. 1–5.

13. Клименко А. Б. Методика выбора способа управления распределенными информационными системами в условиях высокой динамики сетевой инфраструктуры // Известия Юго-Западного государственного университета. 2022. Т. 26, № 1. P. 57–72.

14. RouteNet-Fermi: Network Modeling With Graph Neural Networks / M. Ferriol-Galmés [et al.] // IEEE/ACM Transactions on Networking. 2023. Vol. 31, N 6. P. 3080–3095.

15. Bicski B., Pekar A. Early Detection of Network Service Degradation: An Intra-Flow Approach // 2024 20th International Conference on Network and Service Management (CNSM). Prague: IEEE, 2024. P. 1–5.

16. Graf F., Watteyne T., Villnow M. Monitoring Performance Metrics in Low-Power Wireless Systems // ICT Express. 2024. Vol. 10, N 5. P. 989–1018.

17. Espinal A., Sanchez Padilla V. Queuing Delay Reduction based on Network Traffic Patterns: A Predictive QoS Framework For Point-To-Point Communications // Transport and Telecommunication Journal. 2025. Vol. 26, N 3. P. 237–249.

18. Ali S. Hong, Cheung T. Congestion or No Congestion: Packet Loss Identification and Prediction Using Machine Learning // 2024 International Conference on Platform Technology and Service (PlatCon). Jeju, 2024. P. 72–76.

19. Jin Q. Optimized transmission of multi-path low-latency routing for electricity internet of things based on SDN task distribution // PLoS One. 2025. N 20(2). P. 1–23. <https://doi.org/10.1371/journal.pone.0314253>.

20. Alauthman A., Al-Hyari A. Analysis of LTE/5G network performance parameters in smartphone use cases: a study of packet loss, delay and slice types // International Journal of Computer Networks & Communications (IJCNC). 2025. Vol. 17, N 4. P. 75–93.

21. A Comparative Study of TCP and UDP Performance Using NS-3 Simulation / G. Gaoyang, C. Zhiyi, F. Qamar, A. Hafizah Mohd Aman // Asia-Pacific Journal of Information Technology and Multimedia. 2025. N 14(1). P. 1–19.

References

1. Petushkov G.V. Computational system performance evaluation. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2025;29(2):201-220. (In Russ.)

2. Hassan S.O. AD-RED: A new variant of random early detection AQM algorithm. *Journal of High Speed Networks*. 2024;30(1):53-67.

3. Toopchinezhad M.P., Ahmadi M. Machine learning approaches for active queue management: A survey, taxonomy, and future directions. Available at: <https://arxiv.org/abs/2410.02563> (accessed 15.03.2026).

4. Gadasin D.V., Kobelkova A.D., Rodina A.A., Surova M.A. Network traffic optimization technologies. *Sistemy sinkhronizatsii, formirovaniya i obrabotki signalov = Synchronization Systems, Signal Generation and Processing*. 2025;16(3):9–16. (In Russ.)

5. Muhammad S., Chaudhery T.J., Noh Y. Study on performance of AQM schemes over TCP variants in different network environments. *IET Communications*. 2021;(15):93-111. <https://doi.org/10.1049/cmu2.12061>.
6. Khandozhko V.A., Fedonin O.N., Matlakhov V.P., Khandozhko A.V. Mathematical modeling of automatic control system by numerical integration. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2025;29(2):55-70. (In Russ.)
7. Gong T., Lee J., Cheng X., Xie Y. Neural network-based CUSUM for online change-point detection. Available at: <https://arxiv.org/abs/2210.17312> (accessed 15.03.2026).
8. Shimono M., et al. Performance measurement of Bayesian online changepoint detection and its application. In: *Second International Conference on Advanced Robotics, Automation Engineering, and Machine Learning (ARAEML 2025)*. Vol. 13815. SPIE; 2025. P. 83–103.
9. Tsaknaki I.-Y., Lillo F., Mazzarisi P. Bayesian Autoregressive Online Change-Point Detection with Time-Varying Parameters. Available at: <https://arxiv.org/abs/2407.16376> (accessed 15.03.2026).
10. Corneck J., et al. Online Bayesian changepoint detection for network Poisson processes with community structure. *Statistics and Computing*. 2025;35(3):1-29.
11. Bekhtin Y.S., Balanev K.S. Simulation Modeling Network Traffic Behavior Using Regression Analysis in Wavelet Domain. In: *2024 6th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE)*. Moscow: IEEE; 2024. P. 1–6.
12. Bekhtin Y.S., Balanev K.S., Dubrovskaya E.A., Pavlovich A.V. Stability Appraisal of the Wavelet-and-Regression Method for Unsteady Network Traffic Trend Highlighting. In: *2025 7th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE)*. Moscow: IEEE; 2025. P. 1–5.
13. Klimenko A.B. A Technique of the Distributed Information Systems Control Method Choice under the High Network Dynamics Conditions. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2022;26(1):57-72. (In Russ.)
14. Ferriol-Galmés M., et al. RouteNet-Fermi: Network Modeling With Graph Neural Networks. *IEEE/ACM Transactions on Networking*. 2023;31(6):3080-3095.
15. Bicski B., Pekar A. Early Detection of Network Service Degradation: An Intra-Flow Approach. In: *2024 20th International Conference on Network and Service Management (CNSM)*. Prague: IEEE; 2024. P. 1–5.
16. Graf F., Watteyne T., Villnow M. Monitoring Performance Metrics in Low-Power Wireless Systems. *ICT Express*. 2024;10(5):989-1018.
17. Espinal A., Sanchez Padilla V. Queuing Delay Reduction based on Network Traffic Patterns: A Predictive QoS Framework For Point-To-Point Communications. *Transport and Telecommunication Journal*. 2025;26(3):237-249.
18. Ali I., Hong S., Cheung T. Congestion or No Congestion: Packet Loss Identification and Prediction Using Machine Learning. In: *2024 International Conference on Platform Technology and Service (PlatCon)*. Jeju; 2024. P. 72–76.

19. Jin Q. Optimized transmission of multi-path low-latency routing for electricity internet of things based on SDN task distribution. *PLoS One*. 2025. P. 1–23. <https://doi.org/10.1371/journal.pone.0314253>.
20. Alauthman A., Al-Hyari A. Analysis of LTE/5G network performance parameters in smartphone use cases: a study of packet loss, delay and slice types. *International Journal of Computer Networks & Communications (IJCNC)*. 2025;17(4):75–93.
21. Gaoyang G., Zhiyi C., Qamar F., Hafizah Mohd Aman A. A Comparative Study of TCP and UDP Performance Using NS-3 Simulation. *Asia-Pacific Journal of Information Technology and Multimedia*. 2025;(14):1-19.
-

Информация об авторах / Information about the Authors

Бехтин Юрий Станиславович, доктор технических наук, профессор кафедры прикладной математики и искусственного интеллекта, Национальный исследовательский университет «МЭИ», г. Москва, Российская Федерация, e-mail: yuri.bekhtin@yandex.ru, ORCID: 0000-0001-9963-7244, Author ID: 518783

Yuri S. Bekhtin, Dr. Sci. (Engineering), Professor at the Department of Applied Mathematics and Artificial Intelligence, National Research University "Moscow Power Engineering Institute", Moscow, Russian Federation, e-mail: yuri.bekhtin@yandex.ru, ORCID: 0000-0001-9963-7244, Author ID: 518783

Баланев Кирилл Сергеевич, аспирант, Национальный исследовательский университет «МЭИ», г. Москва, Российская Федерация, e-mail: balanev.kirill@yandex.ru, ORCID: 0009-0002-9722-7262, Author ID: 1204517

Kirill S. Balanev, Postgraduate, National Research University "Moscow Power Engineering Institute", Moscow, Russian Federation, e-mail: balanev.kirill@yandex.ru, ORCID: 0009-0002-9722-7262, Author ID: 1204517

Титова Анна Владимировна, кандидат технических наук, доцент, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: nyatarr@yandex.ru, ORCID: 0000-0002-1619-2938, Author ID: 1169728

Anna V. Titova, Cand. Sci. (Engineering), Associate Professor, Southwest State University, Kursk, Russian Federation, e-mail: nyatarr@yandex.ru, ORCID: 0000-0002-1619-2938, Author ID: 1169728