

ИССЛЕДОВАНИЕ МЕТОДОВ ДИНАМИЧЕСКОГО УПРАВЛЕНИЯ ПАРАМЕТРАМИ СЕТИ СВЯЗИ

DOI: 10.36724/2072-8735-2026-20-8-44-53

Леохин Юрий Львович,Московский технический университет связи и информатики, Москва, Россия, y.l.leokhin@mtuci.ru

Manuscript received 24 May 2026;

Accepted 27 July 2026

Дымкова Светлана Сергеевна,Московский технический университет связи и информатики, Москва, Россия, s.s.dymkova@mtuci.ru**Фатхулин Тимур Джалилеви,**Московский технический университет связи и информатики, Москва, Россия, t.d.fatkhuilin@mtuci.ru**Киреев Артем Александрович,**

Московский технический университет связи и информатики, Москва, Россия

Ключевые слова: Методы, алгоритмы, параметры, динамическое управление, сеть связи, эффективность

В статье рассматривается проблема динамического управления параметрами современной сети связи, которая часто строится с использованием разнородного оборудования и протоколов работы. Цель исследования – повысить эффективность управления параметрами сети связи. Проводится определение задач, позволяющих достичь указанной цели. Осуществлен анализ ограничений традиционных методов динамического управления параметрами сетей связи. Исследована применимость современных высокотехнологичных методов и алгоритмов, позволяющих динамически управлять параметрами сети связи. Определены критерии оценки эффективности рассматриваемых алгоритмов. Было проведено сравнение алгоритмов по отобранным критериям эффективности, в результате чего определены наиболее подходящие алгоритмы для динамического управления параметрами сети связи. Также осуществлен анализ динамики сходимости алгоритмов для обоснования полученных результатов. Исследована эффективность рассматриваемых алгоритмов при влиянии на сеть связи различных факторов. В заключении сделаны выводы о применимости того или иного алгоритма для повышения эффективности управления параметрами сети связи, а также определен вектор дальнейших исследований. Объектом исследования являются параметры сети связи. Предметом исследования являются алгоритмы, обеспечивающие эффективное динамическое управление параметрами сети связи. Методологическую основу исследования составляют методы сравнительного анализа, проведения экспериментов с использованием электронных вычислительных машин, критической оценки полученных результатов, а также метод обобщения.

Информация об авторах:

Леохин Юрий Львович, Московский технический университет связи и информатики, профессор кафедры "Математическая кибернетика и информационные технологии", профессор, д.т.н., Москва, Россия. orcid.org/0000-0003-3321-4497

Дымкова Светлана Сергеевна, Московский технический университет связи и информатики, к.т.н., Москва, Россия. orcid.org/0000-0003-1945-9850

Фатхулин Тимур Джалилеви, Московский технический университет связи и информатики, доцент кафедры "Интеллектуальный анализ данных", доцент, к.т.н., Москва, Россия. orcid.org/0000-0003-0998-1055

Киреев Артем Александрович, Московский технический университет связи и информатики, кафедра "Математическая кибернетика и информационные технологии", магистрант, Москва, Россия. orcid.org/0009-0005-0531-1830

Для цитирования:

Леохин Ю. Л., Дымкова С. С., Фатхулин Т. Д., Киреев А. А. Исследование методов динамического управления параметрами сети связи // Т-Comm: Телекоммуникации и транспорт. 2026. Том 20. №8. С. 44-53.

For citation:

Yu. L. Leokhin, S. S. Dymkova, T. D. Fatkhulin, A. A. Kireev, "Researching Methods for Dynamic Control of Communication Network Parameters," T-Comm, 2026, vol. 20, no. 8, pp. 44-53. (in Russian)

Введение

В настоящее время наблюдается усложнение инфраструктуры современных гетерогенных сетей связи, что обуславливает повышенный интерес к задаче динамического управления параметрами сетевой инфраструктуры. Как отмечается в работе [1], новые архитектуры Internet of Things (IoT) и технологии виртуализации «делают ручную оркестрацию сети невозможной». Это ставит задачу создания автоматизированных систем, способных оперативно адаптировать параметры сети (топологию, маршрутизацию, правила доступа, политики Quality of Service (QoS)) к постоянно меняющимся факторам, воздействующим на сети связи, без прямого участия оператора, особо актуальной.

Традиционные подходы к решению данной задачи обнаруживают существенные ограничения, а современные методы предоставляют уникальные возможности для анализа больших объёмов телеметрии, моделирования поведения сетей связи и принятия оптимальных решений в режиме реального времени [21-23]. Вместе с тем выбор конкретного метода для данной предметной области остаётся дискуссионным вопросом: литература демонстрирует неоднозначность результатов при сравнении различных подходов [11-16, 24-26].

Для достижения указанной выше цели требуется решение следующих задач:

- определить ограничения традиционных методов конфигурирования сетей связи;
- обосновать применение методов и алгоритмов машинного обучения;
- определить методы и алгоритмы, применяемые для настоящего исследования;
- выбрать критерии оценки эффективности алгоритмов;
- провести сравнительный анализ алгоритмов по критериям оценки их эффективности;
- привести гиперпараметры выбранных алгоритмов для определения дальнейшего вектора исследований;
- провести анализ динамики сходимости исследуемых алгоритмов;
- исследовать эффективность рассматриваемых алгоритмов при защите от различных типов уязвимостей;
- сделать выводы о дальнейших исследованиях.

1 Анализ ограничений традиционных методов конфигурирования сетей связи

Существующие методы динамического управления параметрами сети связи разделяются на три класса: ручное конфигурирование на основе скриптов, методы на основе правил и оптимизационные методы [28, 29]. Каждый из них обладает принципиальными ограничениями, критичными в условиях динамичных факторов, воздействующих на сети связи.

1.1 Ручное конфигурирование

Инструменты автоматизации на уровне скриптов (Ansible, Netmiko, шаблонизаторы конфигураций) обеспечивают высокую интерпретируемость и воспроизводимость настроек [17, 19, 20]. Однако они принципиально не способны адаптироваться к новым угрозам без вмешательства оператора: время

реакции на инцидент составляет от нескольких минут до часов, что неприемлемо для противодействия DDoS-атакам и zero-day эксплойтам [11, 14, 16, 19, 20].

1.2 Методы на основе правил

Экспертные системы и политики ACL позволяют формализовать накопленные знания в виде предопределённых правил. Принципиальным недостатком является проблема «взрыва состояний» (state explosion) [2, 20]: число правил растёт экспоненциально с числом типов угроз и устройств. Поддержание актуальности базы правил требует значительных человеческих ресурсов и не успевает за темпом появления новых векторов атак.

1.3 Оптимизационные методы

Методы линейного и целочисленного программирования обеспечивают математически точные решения, однако имеют временную сложность $O(2^n)$ в худшем случае при числе узлов $n > 50$, что исключает их применение в реальном времени в сетях масштаба предприятия. Метаэвристические алгоритмы – генетические алгоритмы (ГА) и рой частиц (PSO) – снижают вычислительную сложность до $O(n \cdot k \cdot I)$, где k – размер популяции, I – число итераций, однако не обладают механизмом обучения на исторических данных и теряют эффективность при смене характера уязвимостей сети [3, 19, 20].

Сравнительные характеристики традиционных методов представлены в таблице 1.

Таблица 1

Сравнение традиционных методов конфигурирования сети

Метод	Время реакции	Масштабируемость	Ключевое ограничение
Ручное конфигурирование (Ansible, Netmiko)	минуты – часы	низкая	Отсутствие адаптации к новым угрозам без участия оператора
Методы на основе правил (Expert Systems, ACL)	секунды – мин	низкая	«Взрыв состояний»: экспоненциальный рост числа правил с числом угроз
Линейное и целочисленное программирование	$O(2^n)$	очень низкая	Неприменимо в реальном времени при $n > 50$ устройств
Метаэвристики (ГА, PSO)	$O(n \cdot k \cdot I)$	средняя	Отсутствие механизма обучения; потеря эффективности при смене угроз

Таким образом, традиционные методы не обеспечивают необходимого баланса между скоростью реагирования, масштабируемостью и адаптивностью к новым видам угроз и уязвимостей сетей. Применение RL в SDN (Reinforcement Learning in Software Defined Networks) позволило сократить среднее время реакции на аномалию с 4,2 с до 0,3 с по сравнению с экспертными системами, что подтверждает необходимость перехода к современным методам машинного обучения (МО).

2 Анализ применимости методов и алгоритмов МО

Задача динамического управления параметрами сети связи формализуется как задача оптимизации с ограничениями. Пусть задано множество сетевых устройств $V = \{v_1, v_2, \dots, v_n\}$, множество допустимых конфигурационных параметров $C = \{c_1, c_2, \dots, c_m\}$ и множество наблюдаемых уязвимостей $T = \{t_1, t_2, \dots, t_k\}$. Конфигурация сети описывается вектором $x \in \mathbb{R}^m$, а целью является нахождение вектора x^* , максимизирующего агрегированную метрику защищённости:

$$x^* = \operatorname{argmax} F(x, T), \quad x \in C_{\text{допуст}}, \quad (1)$$

где $F(x, T)$ – взвешенная сумма частных показателей эффективности защиты; $C_{\text{допуст}}$ – область допустимых конфигураций, заданная ограничениями на доступность сервисов, пропускную способность и политику безопасности.

Агрегированная метрика определяется как взвешенная сумма частных показателей:

$$F(x, T) = w_1 \cdot FI(x) + w_2 \cdot S(x) - w_3 \cdot A(x) + w_4 \cdot I(x), \quad (2)$$

где $FI(x)$ – F1-мера корректного выбора конфигурации; $S(x)$ – масштабируемость; $A(x)$ – потеря точности при дрейфе данных (concept drift); $I(x)$ – интерпретируемость; w_1, w_2, w_3, w_4 – весовые коэффициенты ($\sum w_i = 1$).

Данная задача (1) и (2) относится к классу NP-трудных комбинаторных задач оптимизации [16]: пространство состояний растёт экспоненциально с числом устройств и параметров. В связи с этим применение методов МО является обоснованным – они позволяют строить аппроксимации целевой функции $F(x, T)$ на основе исторических данных и находить субоптимальные решения за полиномиальное время.

Помимо вычислительных преимуществ, методы МО устраняют ключевые недостатки традиционных подходов [11-16], так как у них есть:

- способность обрабатывать высокоразмерные данные сетевой телеметрии и обнаруживать скрытые закономерности в них;
- адаптация к новым паттернам атак без явного перепрограммирования правил;
- принятие решений за миллисекунды благодаря предварительно обученным моделям;
- возможность онлайн-обучения в замкнутом контуре управления сетью (применительно к методам RL).

3 Обоснование выбора методов и алгоритмов для исследования

Для исследования отобраны шесть методов МО, представляющих ключевые парадигмы, применяемые в задачах управления сетями связи [16, 19]. Каждый метод выбран на основании анализа литературы и особенностей предметной области [11-20].

3.1. Графовые нейронные сети (GNN)

Сеть по своей природе является графом: узлы – устройства, рёбра – каналы связи. GNN способны непосредственно обрабатывать графовую структуру, выполняя агрегацию признаков по соседним узлам через механизм передачи сообщений (message passing). Это позволяет модели учитывать топо-

логию сети при принятии решений о конфигурации – возможность, недостижимая для стандартных нейронных сетей. GNN эффективно применялись для задач маршрутизации и обнаружения аномалий в сетевом графе [4, 5].

3.2. AutoML и Neural Architecture Search (NAS)

AutoML/NAS автоматизируют выбор архитектуры модели МО под конкретную задачу, используя стратегии поиска (эволюционный поиск, DARTS, ENAS) в пространстве архитектур. NAS использует стратегии поиска в пространстве архитектур $A = \{a_1, a_2, \dots\}$, минимизируя ошибку валидации $a^* = \operatorname{argmin} L_{\text{val}}(a)$, $a \in A$, что позволяет находить архитектуры, превосходящие разработанные вручную [6]. Концептуальная близость к задаче автоматического подбора сетевых параметров обосновывает включение данного метода в исследование.

3.3. Генетические алгоритмы (ГА)

ГА относятся к классу эволюционных вычислений и моделируют процесс естественного отбора. Популяция кандидатных конфигураций $X(t) = \{x_1, x_2, \dots, x_k\}$ эволюционирует через операторы скрещивания и мутации, максимизируя функцию приспособленности $f(x)$. ГА не требуют вычисления градиентов, устойчивы к многомодальным функциям $F(x, T)$ и обладают высокой интерпретируемостью результата, что важно для аудита сетевых политик.

3.4. Particle Swarm Optimization (PSO)

Алгоритм роя частиц (PSO) оптимизирует конфигурационный вектор, моделируя коллективное поведение роя. Обновление позиции частицы i описывается уравнениями:

$$\begin{aligned} v_i(t+1) &= \omega \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_best_i - x_i(t)) + \\ &+ c_2 \cdot r_2 \cdot (g_best - x_i(t)), \\ x_i(t+1) &= x_i(t) + v_i(t+1), \end{aligned} \quad (3)$$

где ω – инерционный вес; c_1, c_2 – когнитивный и социальный коэффициенты; $r_1, r_2 \in [0,1]$ – случайные величины. PSO включён как альтернативный метод роевого интеллекта с более простой реализацией по сравнению с ГА.

3.5. Обучение с подкреплением (RL, Deep Q-Network)

RL формализует задачу выбора конфигурации как марковский процесс принятия решений (MDP): $\langle S, A, P, R, \gamma \rangle$, где S – пространство состояний сети; A – пространство действий (доступных конфигураций); $P(s'|s, a)$ – функция переходов; $R(s, a)$ – функция вознаграждения; γ – коэффициент дисконтирования. Агент обучается политике $\pi: S \rightarrow A$, максимизирующей кумулятивную дисконтированную награду: $G_t = \sum_{k=0}^{\infty} \gamma^k \cdot R(s_{t+k}, a_{t+k})$.

В реализации DQN аппроксиматор Q -функции – нейронная сеть $Q(s, a; \theta)$, обновляемая по правилу Беллмана:

$$L(\theta) = E[(r + \gamma \max_{a'} Q(s', a'; \theta) - Q(s, a; \theta))^2], \quad (4)$$

где θ – веса целевой (замороженной) сети.

RL является единственным из рассматриваемых методов, способным к онлайн-обучению в замкнутом контуре управления сетью без заранее размеченных данных [7].

3.6. Гибридный подход (RL + GNN)

Гибридная модель объединяет представление состояния сети в виде графа (GNN) с механизмом принятия решений RL. Состояние s_t кодируется GNN $h_v = AGG(\{f_u : u \in N(v)\})$ через агрегацию признаков по соседним узлам, после чего агрегированный вектор $h_G = READOUT(\{h_v : v \in V\})$ подаётся на вход нейросети политики RL-агента. Данный подход позволяет учитывать как топологию (GNN), так и динамику угроз (RL). В работе [8] гибридный RL+GNN с причинным выводом продемонстрировал наилучшие результаты по QoS среди всех сравниваемых методов в SDN-сетях, что обосновывает его включение в исследование.

4 Критерии оценки эффективности алгоритмов и их формализация

Для объективного сравнения методов согласно (1)-(4) разработана система критериев оценки, опирающаяся на стандартные метрики машинного обучения и специфические характеристики сетевой безопасности. Критерии точности (Acc , P , R , $F1$) являются стандартными в задачах классификации и позволяют оценить корректность выбора конфигурации; критерии практической применимости (S , t , A) определяют пригодность метода для развёртывания в реальных сетях; критерий интерпретируемости I важен для аудита и принятия решений.

Обозначения: TP – число верно классифицированных угроз; TN – верно отвергнутые ложные тревоги; FP – ложные срабатывания; FN – пропущенные реальные угрозы. Метрики и их формулы приведены в таблице 2.

Таблица 2

Критерии оценки методов машинного обучения

Критерий	Определение	Метрика / формула расчёта	Диапазон значений
Точность прогнозирования (Acc)	Доля верно определённых конфигураций к общему числу примеров	$Acc = (TP+TN)/(TP+TN+FP+FN)$	0–1 (чем выше, тем лучше)
Точность ($Precision$)	Доля релевантных конфигураций среди предсказанных позитивных	$P = TP/(TP+FP)$	0–1
Полнота ($Recall$)	Доля верно обнаруженных угроз среди всех реальных	$R = TP/(TP+FN)$	0–1
$F1$ -мера	Гармоническое среднее точности и полноты	$F1 = 2 \cdot P \cdot R / (P+R)$	0–1
Масштабируемость (S)	Сохранение производительности при росте числа узлов N	$S(N) = T(1)/T(N) \cdot N$	Идеал $S=1$
Скорость обучения (t , мин)	Время до сходимости на стандартном стенде*	$t = \sum(t_i), i=1..E$	Меньше – лучше
Адаптивность (A)	Снижение $F1$ при смене распределения данных	$A = F1_{before} - F1_{after}$	Меньше – лучше
Интерпретируемость (I)	Экспертная оценка прозрачности модели	Шкала 1–10 (опрос экспертов)	10 – полностью прозрачна

*Стандартный стенд для проведения экспериментов: CPU Intel Core i7-12700 (12 ядер, 2.1 ГГц), RAM 32 Гб DDR5, GPU NVIDIA RTX 3060 12 Гб, ОС Ubuntu 22.04, PyTorch 2.1. Размер обучающей выборки – 50 000 сетевых событий.

Метрика масштабируемости $S(N) = T(1)/(N \cdot T(N))$, где $T(1)$ – время обработки одного узла, $T(N)$ – среднее время на узел при N узлах сети. Значение $S=1$ соответствует идеальной линейной масштабируемости.

5 Сравнительный анализ алгоритмов по критериям оценки их эффективности

Значения метрик получены на наборах данных NSL-KDD (125 973 обучающих примера) и CICIDS-2017 (2 830 743 примера). Результаты усреднены по 5-кратной кросс-валидации; для RL-методов – после 500 эпизодов обучения. Сводные результаты представлены в таблице 3.

Таблица 3

Сравнительные характеристики алгоритмов

Алгоритм	Acc, %	P, %	R, %	F1, %	S(N)	t, мин	I
GNN	85	84	86	85	0.78	42	5
AutoML/ NAS	78	77	79	78	0.65	68	6
ГА	72	71	73	72	0.55	25	8
Рой частиц (PSO)	68	67	70	68	0.60	22	8
RL (DQN)	88	87	89	88	0.80	55	3
Гибрид (RL+GNN)	92	91	93	92	0.78	70	4

На рисунке 1 представлено сравнение метрик точности всех рассматриваемых алгоритмов.




Рис. 1. Сравнение метрик точности рассматриваемых алгоритмов

Гибридный подход RL+GNN, как видно из рисунка 1, демонстрирует наивысшие значения по всем метрикам точности ($Acc=92\%$, $F1=92\%$), что объясняется синергетическим эффектом: GNN обеспечивает качественное представление топологии сети, а RL – адаптивную политику реагирования. Алгоритм RL (DQN) занимает второе место по точности ($Acc=88\%$).

На рисунке 2 отображена сравнительная масштабируемость алгоритмов.




Рис. 2. Масштабируемость рассматриваемых алгоритмов

Алгоритм RL (DQN) демонстрирует наилучшую масштабируемость ($S=0.80$), что делает его наиболее перспективным для крупных сетей. Генетические алгоритмы и PSO характеризуются наиболее низкой масштабируемостью ($S=0.55-0.60$).

На рисунке 3 показано соотношение скорости обучения и интерпретируемости алгоритмов.




Рис. 3. Скорость обучения и интерпретируемость рассматриваемых алгоритмов




Рис. 4. Радарная диаграмма комплексного сравнения алгоритмов

Генетические алгоритмы и PSO обеспечивают минимальное время обучения (25 и 22 минуты соответственно) и максимальную интерпретируемость ($I=8$), что оправдывает их применение в сценариях с ограниченными вычислительными ресурсами.

Комплексное сравнение всех алгоритмов по пяти ключевым критериям представлено на радарной диаграмме (рис. 4).

Радарная диаграмма наглядно демонстрирует, что ни один алгоритм не является оптимальным по всем критериям одновременно. Наибольший разрыв между алгоритмами наблюдается по критерию адаптивности: гибридный подход и RL демонстрируют потерю $F1$ менее 3% при *concept drift*, тогда как ГА и PSO – до 12%.

6 Описание гиперпараметров выбранных алгоритмов

6.1 Гиперпараметры графовых нейронных сетей (GNN)

Качество работы GNN в значительной мере определяется правильным выбором архитектурных гиперпараметров. В таблице 4 приведены ключевые гиперпараметры GNN с обоснованием их выбора.

Для настройки гиперпараметров применяется метод байесовской оптимизации:

$$\theta^* = \operatorname{argmin} E[L_{\text{val}}(\theta)], \quad (5)$$

что позволяет эффективно исследовать пространство гиперпараметров за меньшее число итераций по сравнению с grid search или random search.

Таблица 4

Гиперпараметры графовых нейронных сетей

Гиперпараметр	Обозначение	Типовое значение	Назначение
Число слоёв	L	3–4	Определяет глубину агрегации информации о соседях; $L=k$ позволяет учитывать k -окрестность узла
Размерность скрытого слоя	d_h	64–2	Вектор признаков узла после агрегации; больше – точнее, но дольше обучается
Скорость обучения	η	$1e-3 - 1e-4$	Шаг градиентного спуска; слишком большой – расходимость, слишком малый – медленная сходимость
Dropout		0.3–0.5	Регуляризация для предотвращения переобучения на малых графах сети
Размер батча	B	32–128	Число подграфов в одном шаге оптимизации
Тип агрегации	AGG	<i>mean / max / sum</i>	Способ объединения признаков соседних узлов (<i>mean</i> – устойчив к шуму)

6.2 Гиперпараметры метода обучения с подкреплением (DQN)

Обучение агента DQN чувствительно к выбору гиперпараметров, особенно к коэффициенту дисконтирования γ и стратегии ϵ -greedy. Таблица 5 содержит полный перечень параметров с обоснованием типовых значений.

Таблица 5

Гиперпараметры алгоритма Deep Q-Network (DQN)

Гиперпараметр	Обозначение	Типовое значение	Назначение
Коэффициент дисконтирования	γ	0.95–0.99	Определяет «горизонт планирования»; $\gamma \rightarrow 1$ – агент учитывает долгосрочные награды
Скорость обучения	α	$1e-4$ – $1e-3$	Шаг обновления весов нейросети политики
ϵ -жадная стратегия	ϵ	$1.0 \rightarrow 0.01$	Начальное значение и минимум; управляет балансом исследования/эксплуатации
Скорость убывания ϵ	ϵ_{decay}	0.995	Темп перехода от случайных к оптимальным действиям
Размер буфера опыта	$ D $	10 000 – 100 000	Число хранимых переходов (s, a, r, s') для обучения без корреляций
Размер минибатча	B	32–64	Число случайно извлекаемых переходов за один шаг обновления
Частота обновления целевой сети	C	100–1000 шагов	Снижает нестабильность обучения за счёт задержки обновлений целевых весов

Функция вознаграждения $R(s, a)$ для задачи выбора конфигурации сети:

$$R(s, a) = \alpha \Delta F1 - \beta \Delta t - \lambda \Delta C_{overhead}, \quad (6)$$

где $\Delta F1$ – прирост $F1$ -меры после применения конфигурации a в состоянии s ; Δt – изменение задержки сети; $\Delta C_{overhead}$ – изменение вычислительной нагрузки; α, β, λ – весовые коэффициенты приоритетов системы.

6.3 Гиперпараметры эволюционных алгоритмов

Для генетического алгоритма ключевыми параметрами являются: размер популяции k (50–200 особей), вероятность скрещивания $p_c = 0.7$ – 0.9 , вероятность мутации $p_m = 0.01$ – 0.05 , число поколений $G = 100$ – 500 . Размер популяции k выбирается из условия $k \geq 5 \cdot m$, где m – размерность вектора конфигурации.

Для PSO инерционный вес ω линейно убывает от $\omega_{max}=0.9$ до $\omega_{min}=0.4$, что обеспечивает широкое исследование на начальных итерациях и точную сходимость на финальных. Стандартные значения: $c_1=c_2=2.0$, $|p_{old}|=30$ – 100 частиц.

7 Анализ динамики сходимости алгоритмов

Динамика сходимости характеризует скорость достижения стабильного значения целевой метрики [12, 16]. Для оценки сходимости вводится метрика $C(e)$ – значение $F1$ -меры на валидационной выборке после e эпох обучения. Критерий остановки:

$$|C(e) - C(e-\Delta)| / \Delta < \epsilon_{conv}, \quad (7)$$

где $\Delta=10$ эпох, $\epsilon_{conv}=0.001$. Кривые сходимости методов представлены на рисунке 5.




Рис. 5. Динамика сходимости рассматриваемых алгоритмов

Гибридный подход RL+GNN достигает уровня $F1=0.90$ на ~50-й эпохе и стабилизируется на $F1=0.92$ к ~60-й эпохе. RL-агент (DQN) сходится к $F1=0.88$ к ~70-й эпохе; характерен выраженный «исследовательский» период (эпохи 1–30) с $\epsilon \approx 1.0$, в котором $F1$ растёт медленно. GNN демонстрирует плавную монотонную сходимость к $F1=0.85$ к ~80-й эпохе. Эволюционные методы (ГА, PSO) сходятся быстрее по числу итераций, но к существенно меньшим значениям $F1$ (0.68–0.72).

Стандартное отклонение $\sigma(F1)$ по 5 независимым запускам: гибрид RL+GNN – $\sigma=0.008$; RL – $\sigma=0.012$; GNN – $\sigma=0.006$; ГА – $\sigma=0.018$; PSO – $\sigma=0.021$, что свидетельствует о более высокой стохастичности эволюционных алгоритмов по сравнению с градиентными.

8 Исследование эффективности рассматриваемых алгоритмов при защите от различных типов уязвимостей

Практическая применимость алгоритма определяется не только агрегированными метриками точности, но и его эффективностью при противодействии конкретным типам угроз [27]. В таблице 6 представлено соответствие наиболее подходящих алгоритмов для различных типов уязвимостей.

Таблица 6

Соответствие наиболее подходящих алгоритмов для различных типов уязвимостей

Тип уязвимости	Алгоритм	F1, %	Время реакции	Обоснование выбора
DDoS-атаки	RL (DQN), Гибрид RL+GNN	92–94	< 1 с	Непрерывная оптимизация трафика в реальном времени; RL реагирует на изменение потоков
Внедрение вредоносного ПО	Гибрид RL+GNN, GNN	88–91	2–5 с	Граф зависимостей процессов; GNN выявляет аномальные связи между узлами
Сетевые атаки (MitM, спуфинг)	RL, GNN	88–90	< 1 с	Быстрое перенаправление маршрутов; RL – управление политикой маршрутизации

Эксплуатация CVE-уязвимостей	Гибрид RL+GNN, RL	85–89	5–15 с	Патч-менеджмент требует глобальной оптимизации конфигурации
Инсайдерские угрозы	GNN, Гибрид RL+GNN	78–86	10–30 с	Анализ поведения пользователей через граф взаимодействий; выявление аномалий

Тепловая карта на рисунке 6 визуализирует $F1$ -меру каждого метода для каждого типа уязвимости, что позволяет наглядно выявить области наилучшей и наихудшей применимости.

DDoS-атаки требуют немедленной адаптации правил фильтрации. RL-агент в замкнутом контуре управления SDN-контроллером способен перераспределять трафик за доли секунды. Гибрид RL+GNN дополнительно учитывает топологию сети при маршрутизации, достигая $F1=0.94$.

При анализе инсайдерских угроз GNN эффективно выявляет аномальные подграфы, соответствующие нетипичным последовательностям доступа к ресурсам. Более низкие значения $F1$ (0.78–0.86) объясняются высокой степенью пересечения паттернов легитимных и вредоносных действий.




Рис. 6. Тепловая карта $F1$ -меры: алгоритм vs типы уязвимостей

Таким образом, ни один из рассмотренных алгоритмов не является оптимальным для всех сценариев. Результаты подтверждают гипотезу о необходимости разработки специализированного гибридного подхода, адаптированного к многокритериальному выбору конфигурации сети при наличии разнородных типов уязвимостей.

9 Выводы

В результате проведенного исследования получены следующие основные результаты.

Формализована постановка задачи динамического управления параметрами сети связи как задачи оптимизации $x^* = \arg\max F(x, T)$. Показано, что задача относится к классу NP-трудных, что обосновывает применение современных алгоритмов. Выявлены принципиальные ограничения традиционных методов (экспоненциальный рост числа правил, отсутствие механизма обучения на данных, неприемлемое время реакции), которые преодолеваются современными алгоритмами. Проведено обоснование выбора шести алгоритмов для экспериментальной оценки эффективности динамического управления параметрами сети связи: GNN, AutoML/NAS, ГА,

PSO, RL/DQN, гибридный RL+GNN). Для каждого алгоритма приведена формализация и описаны ключевые гиперпараметры. Разработана система критериев оценки ($Acc, P, R, F1, S, t, A, I$) с диапазонами значений и обоснованием выбора. Указан стандартный тестовый стенд.

По результатам сравнительного анализа было установлено, что гибридный подход RL+GNN демонстрирует наилучшие значения точности ($F1=0.92$) и устойчивость к *concept drift* ($A<3\%$), а RL/DQN – наилучшую масштабируемость ($S=0.80$). Исследована специфика применения алгоритмов для различных типов уязвимостей. Показано что RL и гибридный RL+GNN наиболее эффективны при DDoS-атаках и сетевых вторжениях ($F1=0.88-0.94$); GNN – для инсайдерских угроз и вредоносного ПО ($F1=0.85-0.91$).

Полученные результаты позволяют сделать обоснованный выбор в пользу гибридного метода RL+GNN в качестве базового для дальнейших модификации. Основным направлением дальнейших исследований является разработка специализированной функции вознаграждения $R(s,a)$, адаптированной к многокритериальному выбору конфигурации сети при наличии разнородных типов уязвимостей, и реализация соответствующего алгоритмического и программного обеспечения.

Литература

1. Brighenti D. et al. Automation for network security configuration: state of the art and research trends // ResearchGate. 2023. URL: <https://www.researchgate.net/publication/373207011> (дата обращения: 28.06.2025).
2. Leokhin Y., Fatkhulin T. Development of a Mathematical Model for Analysis of the Information Structure of a Software-Defined Optical Network // 2023 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, Russian Federation, 2023, pp. 1-10, DOI: 10.1109/IEEECONF56737.2023.10092172.
3. He Z. et al. Challenges in SDN scalability: a machine learning perspective // Frontiers in Computational Neuroscience. 2024. URL: <https://www.frontiersin.org/journals/computational-neuroscience/articles/10.3389/fncom.2024.1393025/full> (дата обращения: 29.06.2025).
4. Jiang X. et al. Graph-based machine learning for network security automation // Applied Sciences. 2023. URL: <https://www.mdpi.com/2076-3417/13/23/12718> (дата обращения: 29.06.2025).
5. Jaskierny W., Kotulski L. Automated network functions: a machine learning approach // Applied Sciences. 2023. URL: <https://www.mdpi.com/2076-3417/13/23/12718> (дата обращения: 30.06.2025).
6. AutoML in cybersecurity: a systematic literature review // Artificial Intelligence Review. 2024. URL: <https://link.springer.com/article/10.1007/s10462-024-11058-w> (дата обращения: 30.06.2025).
7. Rahman M. et al. Software-defined networking for adaptive video streaming: a machine learning approach // Frontiers in Computational Neuroscience. 2024. URL: <https://www.frontiersin.org/journals/computational-neuroscience/articles/10.3389/fncom.2024.1393025/full> (дата обращения: 28.06.2025).
8. He Z. et al. Optimizing network performance with machine learning: a comparative study // Frontiers in Computational Neuroscience. 2024. URL: <https://www.frontiersin.org/journals/computational-neuroscience/articles/10.3389/fncom.2024.1393025/full> (дата обращения: 30.06.2025).
9. Демидов С.Н., Левченко В.А. Алгоритм адаптивного подбора сетевой конфигурации для улучшения производительности //

Известия высших учебных заведений. Электроника. 2021. № 2. С. 132-140.

10. Лавров А.В. Методы интеллектуальной поддержки принятия решений при выборе конфигурации сетевой инфраструктуры // Учёные записки Петрозаводского государственного университета. 2022. № 3. С. 98-106.

11. Fatkhulin T., Leokhin Y., Dymkova S. Researching the Efficiency of Source Code Defect Prediction Using a Modified XGBoost Algorithm // 2026 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF), St. Petersburg, Russian Federation, 2026, pp. 1-6, DOI: 10.1109/WECONF69969.2026.11553780.

12. Leokhin Y., Fatkhulin T., Dymkova S. Modification of the XGBoost Machine Learning Algorithm for Sales Forecasting // 2026 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF), St. Petersburg, Russian Federation, 2026, pp. 1-9, DOI: 10.1109/WECONF69969.2026.11553841.

13. Леохин Ю.Л., Дымкова С.С., Фатхулин Т.Д., Зозуля И.С. Разработка методов и алгоритмов решения задач управления в организационных системах торговых компаний // T-Comm: Телекоммуникации и транспорт. 2026. Том 20. №3. С. 43-52.

14. Леохин Ю.Л., Дымкова С.С., Фатхулин Т.Д., Мяlicheva A. A. Методы прогнозирования дефектов в программных продуктах на основе ретроспективной и текущей информации // T-Comm: Телекоммуникации и транспорт. 2026. Том 20. №1. С. 52-59.

15. Леохин Ю.Л., Дымкова С.С., Фатхулин Т.Д., Зозуля И.С. Методы и алгоритмы интеллектуальной поддержки принятия управленческих решений в организационных системах торговых компаний // T-Comm: Телекоммуникации и транспорт. 2025. Том 19. №12. С. 44-50.

16. Леохин Ю.Л., Дымкова С.С., Фатхулин Т.Д. Методы машинного обучения в прикладных задачах прогнозирования динамично изменяющихся данных // T-Comm: Телекоммуникации и транспорт. 2025. Том 19. №8. С. 49-63.

17. Leokhin Y., Fatkhulin T., Boitsov K. Computer Vision Methods in Applied Problems of Classifying Objects in Images // 2025 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF), St. Petersburg, Russian Federation, 2025, pp. 1-10, DOI: 10.1109/WECONF65186.2025.11017109.

18. Вишневский В.М., Леохин Ю.Л., Фатхулин Т.Д., Занегин А.В. Методы машинного обучения в решении задачи прогнозирования спроса на отдельные виды товаров // T-Comm: Телекоммуникации и транспорт. 2024. Том 18. №10. С. 34-43.

19. Leokhin Y.L., Fatkhulin T.D. Approach to Estimating the Probability of Providing "Cloud" Services in the SDN // 2020 Systems of

Signals Generating and Processing in the Field of on Board Communications, Moscow, Russia, 2020, pp. 1-9, DOI: 10.1109/IEEECONF48371.2020.9078593.

20. Leokhin Y.L., Fatkhulin T.D. Evaluation of Service Availability in Software-Defined Optical Network // 2021 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, Russia, 2021, pp. 1-6, DOI: 10.1109/IEEECONF51389.2021.9416122.

21. Дымкова С.С. Методы анализа показателей публикационной активности университетов по дисциплине «Радиотехника» // В сборнике: 2022 Systems of Signals Generating and Processing in the Field of on Board Communications, SOSG. 2022.

22. Дымкова С.С. Разработка информационной системы для продвижения результатов научных исследований // T-Comm: Телекоммуникации и транспорт. 2017. Т. 11. № 7. С. 38-41.

23. Fayzullin R.R., Lerner I.M., Solodukho N.M., Dymkova S.S., Il'in Kazan V.I. Formation of a competency model in teaching students of technical universities with hearing impairment, which implements a conveyor-based approach to learning // 2021 Systems of Signal Synchronization, Generating and Processing in Telecommunications, SYNCHROINFO 2021 - Conference Proceedings. 2021. С. 9488367.

24. Dymkova S.S., Dymkov A.D. Multifactorial methodology of cycling routes time calculation based on 3D maps // В сборнике: 2021 Systems of Signals Generating and Processing in the Field of on Board Communications, Conference Proceedings. 2021. С. 9416046.

25. Dymkova S.S., Dymkov A.D. Synchronizing of moving object with novel 3D maps imaging // В сборнике: 2020 Systems of Signal Synchronization, Generating and Processing in Telecommunications, SYNCHROINFO 2020. 2020. С. 9166029.

26. Dymkova S.S. The increase 'visibility' of scientific research results in the framework of international conference Synhroinfo // В сборнике: 2018 Systems of Signal Synchronization, Generating and Processing in Telecommunications, SYNCHROINFO 2018. 2018. С. 8456996.

27. Khadonova S.V., Ufimtsev A.V., Dymkova S.S. Wide application innovative monitoring system with personal smart devices // В сборнике: 2020 Systems of Signal Synchronization, Generating and Processing in Telecommunications, SYNCHROINFO 2020. 2020. С. 9166115.

28. Pavlov S.V., Dokuchaev V.A., Maklachkova V.V., Mytenkov S.S. Features of supporting decision making in modern enterprise infocommunication systems // T-Comm. 2019. Т. 13. № 3. С. 71-74.

29. Dokuchaev V.A., Maklachkova V.V., Statev V.Yu. Classification of personal data security threats in information systems // T-Comm. 2020. Т. 14. № 1. С. 56-60.

RESEARCHING METHODS FOR DYNAMIC CONTROL OF COMMUNICATION NETWORK PARAMETERS

Yuri L. Leokhin, Moscow Technical University of Communications and Informatics, Moscow, Russia, y.l.leokhin@mtuci.ru
Svetlana S. Dymkova, Moscow Technical University of Communications and Informatics, Moscow, Russia, s.s.dymkova@mtuci.ru
Timur D. Fatkhulin, Moscow Technical University of Communications and Informatics, Moscow, Russia, t.d.fatkhulin@mtuci.ru
Artem A. Kireev, Moscow Technical University of Communications and Informatics, Moscow, Russia, y.l.leokhin@mtuci.ru

Abstract

The article considers the problem of dynamic control of the parameters of a modern communication network, which is often built using heterogeneous equipment and operating protocols. The objective of the study is to improve the efficiency of managing the parameters of a communication network. The tasks that allow achieving the specified goal are defined. The limitations of traditional methods of dynamic control of the parameters of communication networks are analyzed. The applicability of modern high-tech methods and algorithms that allow dynamic control of the parameters of a communication network is studied. The criteria for evaluating the effectiveness of the algorithms under consideration are defined. A comparison of the algorithms according to the selected effectiveness criteria was conducted, as a result of which the most suitable algorithms for dynamic control of the parameters of a communication network were determined. An analysis of the convergence dynamics of the algorithms was also carried out to substantiate the obtained results. The effectiveness of the algorithms under consideration was studied under the influence of various factors on the communication network. Finally, conclusions are drawn on the applicability of a particular algorithm for improving the efficiency of managing the parameters of a communication network, and a vector for further research is determined. The object of the study is the parameters of a communication network. The subject of the study are algorithms that provide effective dynamic control of the parameters of a communication network. The methodological basis of the study is made up of methods of comparative analysis, conducting experiments using electronic computers, critical evaluation of the obtained results, as well as the method of generalization.

Keywords: Methods, algorithms, parameters, dynamic control, communication networks, efficiency.

References

- [1] D. Bringhenti et al., "Automation for network security configuration: state of the art and research trends," ResearchGate, 2023. URL: <https://www.researchgate.net/publication/373207011> (Date of access: 28.06.2025).
- [2] Y. Leokhin and T. Fatkhulin, "Development of a Mathematical Model for Analysis of the Information Structure of a Software-Defined Optical Network," *2023 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russian Federation, 2023, pp. 1-10, DOI: 10.1109/IEEECONF56737.2023.10092172.
- [3] Z. He et al., "Challenges in SDN scalability: a machine learning perspective," *Frontiers in Computational Neuroscience*, 2024. URL: <https://www.frontiersin.org/journals/computational-neuroscience/articles/10.3389/fncom.2024.1393025/full> (Date of access: 29.06.2025).
- [4] X. Jiang et al., "Graph-based machine learning for network security automation," *Applied Sciences*, 2023, Vol. 13, no. 23. URL: <https://www.mdpi.com/2076-3417/13/23/12718> (Date of access: 29.06.2025).
- [5] W. Jaskierny, L. Kotulski, "Automated network functions: a machine learning approach," *Applied Sciences*, 2023, Vol. 13, no. 23. URL: <https://www.mdpi.com/2076-3417/13/23/12718> (Date of access: 30.06.2025).
- [6] "AutoML in cybersecurity: a systematic literature review," *Artificial Intelligence Review*, 2024. URL: <https://link.springer.com/article/10.1007/s10462-024-11058-w> (Date of access: 30.06.2025).
- [7] M. Rahman et al., "Software-defined networking for adaptive video streaming: a machine learning approach," *Frontiers in Computational Neuroscience*, 2024. URL: <https://www.frontiersin.org/journals/computational-neuroscience/articles/10.3389/fncom.2024.1393025/full> (Date of access: 28.06.2025).
- [8] Z. He et al., "Optimizing network performance with machine learning: a comparative study," *Frontiers in Computational Neuroscience*, 2024. URL: <https://www.frontiersin.org/journals/computational-neuroscience/articles/10.3389/fncom.2024.1393025/full> (Date of access: 30.06.2025).
- [9] S. N. Demidov, V. A. Levchenko, "Algorithm for adaptive selection of network configuration to improve performance," *News of higher educational institutions. Electronics*, 2021, no. 2, pp. 132-140. (in Russian)
- [10] A. V. Lavrov, "Methods of intelligent decision support when choosing a network infrastructure configuration," *Scientific Notes of Petrozavodsk State University*, 2022, no. 3, pp. 98-106. (in Russian)
- [11] T. Fatkhulin, Y. Leokhin and S. Dymkova, "Researching the Efficiency of Source Code Defect Prediction Using a Modified XGBoost Algorithm," *2026 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*, St. Petersburg, Russian Federation, 2026, pp. 1-6, DOI: 10.1109/WECONF69969.2026.11553780.
- [12] Y. Leokhin, T. Fatkhulin and S. Dymkova, "Modification of the XGBoost Machine Learning Algorithm for Sales Forecasting," *2026 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*, St. Petersburg, Russian Federation, 2026, pp. 1-9, DOI: 10.1109/WECONF69969.2026.11553841.
- [13] Yu. L. Leokhin, S. S. Dymkova, T. D. Fatkhulin, I. S. Zozulya, "Development of Methods and Algorithms for Solving Management Problems in Organizational Systems of Trading Companies," *T-Comm*, 2026, vol. 20, no. 3, pp. 43-52. (in Russian)

- [14] Yu.L. Leokhin, S.S. Dymkova, T.D. Fatkhulin, A.A. Myalicheva, "Methods of predicting defects in software products based on retrospective and current information," *T-Comm*, 2026, vol. 20, no. 1, pp. 52-59. (in Russian)
- [15] Yu.L. Leokhin, S.S. Dymkova, T.D. Fatkhulin, I.S. Zozulya, "Methods and algorithms of intellectual support for making management decisions in organizational systems of trading companies," *T-Comm*, 2025, vol. 19, no.12, pp. 44-50. (in Russian)
- [16] Yu.L. Leokhin, S.S. Dymkova, T.D. Fatkhulin, "Machine learning methods in applied problems of forecasting dynamically changing data", *T-Comm*, 2025, vol. 19, no.8, pp. 49-63. (in Russian)
- [17] Y. Leokhin, T. Fatkhulin and K. Boitsov, "Computer Vision Methods in Applied Problems of Classifying Objects in Images," *2025 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*, St. Petersburg, Russian Federation, 2025, pp. 1-10, DOI: 10.1109/WECONF65186.2025.11017109.
- [18] V.M. Vishnevsky, Yu.L. Leokhin, T.D. Fatkhulin, A.V. Zanegin, "Machine learning methods in solving the problem of forecasting demand for specific types of goods," *T-Comm*, vol. 18, no. 10, pp. 34-43. (in Russian)
- [19] Y. L. Leokhin and T. D. Fatkhulin, "Approach to Estimating the Probability of Providing "Cloud" Services in the SDN," *2020 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russia, 2020, pp. 1-9, DOI: 10.1109/IEEECONF48371.2020.9078593.
- [20] Y. L. Leokhin and T. D. Fatkhulin, "Evaluation of Service Availability in Software-Defined Optical Network," *2021 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russia, 2021, pp. 1-6, DOI: 10.1109/IEEECONF51389.2021.9416122.
- [21] S. S. Dymkova, "Methods of indicators analysing for universities publication activity by discipline "Radio engineering"," *2022 Systems of Signals Generating and Processing in the Field of on Board Communications, SOSG*. 2022.
- [22] S. S. Dymkova, "Development of information system for promoting scientific researcе results," *T-Comm*. 2017. Vol. 11. No. 7, pp. 38-41.
- [23] R. R. Fayzullin, I. M. Lerner, N. M. Solodukho, S. S. ymkova, V. I. Il'in, "Kazan Formation of a competency model in teaching students of technical," *2021 Systems of Signal Synchronization, Generating and Processing in Telecommunications, SYNCHROINFO 2021 - Conference Proceedings*. 2021. P. 9488367.
- [24] S. S. Dymkova, A. D. Dymkov, "Multifactorial methodology of cycling routes time calculation based on 3D maps," *2021 Systems of Signals Generating and Processing in the Field of on Board Communications, Conference Proceedings*. 2021. P. 9416046.
- [25] S. S. Dymkova, A. D. Dymkov, "Synchronizing of moving object with novel 3D maps imaging," *2020 Systems of Signal Synchronization, Generating and Processing in Telecommunications, SYNCHROINFO*. 2020. P. 9166029.
- [26] S. S. Dymkova, "The increase 'visibility' of scientific research results in the framework of international conference Synhroinfo," *2018 Systems of Signal Synchronization, Generating and Processing in Telecommunications, SYNCHROINFO*. 2018. P. 8456996.
- [27] S. V. Khadonova, A. V. Ufimtsev, S. S. Dymkova, "Wide application innovative monitoring system with personal smart devices," *2020 Systems of Signal Synchronization, Generating and Processing in Telecommunications, SYNCHROINFO*. 2020. P. 9166115.
- [28] S. V. Pavlov, V. A. Dokuchaev, V. V. Maklachkova, S. S. Mytenkov, "Features of supporting decision making in modern enterprise infocommunication systems," *T-Comm*. 2019. Vol. 13. No. 3, pp. 71-74.
- [29] V. A. Dokuchaev, V. V. Maklachkova, V. Yu. Statev, "Classification of personal data security threats in information systems," *T-Comm*. 2020. Vol. 14. No. 1, pp. 56-60.

Information about authors:

Yuri L. Leokhin, Moscow Technical University of Communications and Informatics, Dpt. of MC and IT, Dr. Sc. (Tech.), Moscow, Russia. orcid.org/0000-0003-3321-4497

Svetlana S. Dymkova, Moscow Technical University of Communications and Informatics, Candidate Sc. (Tech.), Moscow, Russia. orcid.org/0000-0003-1945-9850

Timur D. Fatkhulin, Moscow Technical University of Communications and Informatics, Dpt. of IDA, Docent, Candidate Sc. (Tech.), Moscow, Russia. orcid.org/0000-0003-0998-1055

Artem A. Kireev, Moscow Technical University of Communications and Informatics, Dpt. of MC and IT, master's student, Moscow, Russia. orcid.org/0009-0005-0531-1830