

УДК 004.8:004.7

## ИНТЕГРАЦИЯ МАШИННОГО ОБУЧЕНИЯ В АРХИТЕКТУРУ ИНТЕРНЕТА ВЕЩЕЙ

*Славинский Г.А., магистрант*

*Белорусский государственный университет информатики и радиоэлектроники  
г. Минск, Республика Беларусь*

*Боброва Н.Л. – канд. техн. наук, доцент*

**Аннотация.** В данной статье описываются вычислительные уровни современной архитектуры IoT с поддержкой машинного обучения: Cloud, Fog, Edge. Рассматриваются архитектурные паттерны интеграции на примере MLOps-ориентированной архитектуры и основные стратегии федеративного обучения. Результаты исследования могут быть использованы при проектировании отказоустойчивых и масштабируемых интеллектуальных IoT-систем.

**Ключевые слова.** Машинное обучение, Интернет вещей, MLOps, федеративное обучение.

**Введение.** Концепция Интернет вещей (IoT) предполагает сеть физических объектов, оснащенных встроенными технологиями для взаимодействия между собой и внешней средой. На практике IoT представляют собой сложную многоуровневую структуру, объединяющую физические устройства, сети передачи данных и интеллектуальные платформы обработки информации [1].

В отличие от простых систем сбора и хранения данных, интеллектуальные IoT-платформы обеспечивают анализ, прогнозирование и принятие решений в реальном времени, что позволяет автоматизировать различные бизнес-процессы. Инфраструктура подразумевает как персональные устройства, так и инструменты производственного процесса.

Актуальность тематики обусловлена стремительным развитием технологий искусственного интеллекта, включая направление машинного обучения (ML), и прогнозируемым ростом количества подключенных устройств, которое достигнет 39 миллиардов к 2030 году [2].

Современные ML-архитектуры IoT строятся вокруг трех ключевых уровней обработки: облака (Cloud), промежуточного туманного уровня (Fog) и периферии (Edge). Понимание каждого из этих уровней определяет способность спроектировать отказоустойчивую систему [3].

Цель исследования — определить принципы построения масштабируемых и отказоустойчивых ML-архитектур в экосистемах Интернета вещей на основе трехуровневой модели Cloud-Fog-Edge.

**Облачный уровень.** Данный уровень является центральным компонентом ML-архитектуры в IoT для стратегических задач и отвечает за хранение, обработку и анализ больших объемов данных. Инфраструктура включает высокопроизводительные дата-центры, оснащенные графическими и тензорными ускорителями, большими объемами оперативной памяти и специализированными программными средствами для обучения моделей высокой сложности.

В облаке выполняются наиболее ресурсоемкие задачи: обучение глубоких нейронных сетей, переобучение моделей, хранение метаданных и исторических данных. Оркестрация ML-пайплайнов осуществляется с помощью таких инструментов, как Kubeflow и Apache Airflow.

Преимущество облачного уровня заключается в возможности обслуживания множества устройств, обработке больших массивов данных, поддержке разнообразных типов данных и моделей, а также в создании единого пространства для управления, анализа, принятия решений.

Вместе с тем существуют и ограничения. Передача данных в облако может сопровождаться задержками, что не подходит для приложений критически важной инфраструктуры. Требуется стабильное интернет-соединение. Также для облачного уровня важны механизмы защиты данных — шифрование, управление доступом, а также защита от компрометации.

Облачный уровень оптимален для обучения и обновления моделей, долгосрочной аналитики и выполнения задач, допускающих задержки при передаче данных по сети.

**Периферийный уровень.** Инфраструктура Edge включает устройства, непосредственно взаимодействующие с физической средой, что подразумевает как датчики, микроконтроллеры, так и одноплатные компьютеры, промышленные контроллеры. Главная особенность уровня — обработка данных непосредственно в месте их генерации [3]. Такой подход обеспечивает минимальную задержку, высокую автономность и устойчивость к сбоям сети.

Данный уровень ориентирован на выполнение критически важных задач машинного обучения в реальном времени: фильтрацию телеметрии, обнаружение аномалий и событий, а также принятие решений без обращения к облаку. Из-за ограниченных вычислительных и энергетических ресурсов на периферии используются специально оптимизированные модели.

Обучение на уровне Edge возможно в виде адаптации обученных моделей или участия в федеративном обучении. Данная инфраструктура важна для систем, где задержки недопустимы, таких как робототехника и автономный транспорт.

Ключевые характеристики периферийного уровня — низкая латентность, строгие ограничения по энергопотреблению и памяти.

Для работы в условиях строгих ограничений применяется парадигма TinyML, позволяющая запускать модели непосредственно на микроконтроллерах и во встраиваемых системах [4]. Реализация данного подхода стала возможной благодаря развитию специализированных фреймворков, аппаратных ускорителей и методов оптимизации моделей.

**Промежуточный уровень.** Fog-уровень представляет собой способ организации и координации множества Edge-узлов в рамках локальной сети. Его задача — объединить локальные ресурсы в единую сеть для быстрой обработки данных без обращения к удаленным дата-центрам [5].

Ключевое отличие Fog от Edge заключается в масштабе и роли. Если Edge-устройства отвечают за непосредственное взаимодействие со средой и первичную обработку данных, то Fog-уровень обеспечивает координацию множества Edge-узлов, реализует логику маршрутизации потоков данных и поддерживает работу распределенных приложений в пределах одного объекта.

На данном уровне осуществляется агрегация данных от множества периферийных узлов, выполняются модели средней сложности, производится предварительная обработка, фильтрация и кэширование данных. Поддержка контейнерной оркестрации позволяет развертывать на Fog-узлах сложные сервисы и поддерживать их отказоустойчивость. Таким образом, Fog-уровень выступает в роли локальной системы принятия решений, обеспечивая баланс между вычислительными ресурсами и оперативностью.

Такой подход позволяет снизить нагрузку на каналы связи за счет отправки в облако только полезной информации, подключать новые устройства к ближайшему узлу без перегрузки центрального сервера и координировать работу множества устройств при отсутствии связи с облаком. Однако это также усложняет архитектуру, не исключает проблем совместимости оборудования разных производителей, создает потенциальные точки входа для злоумышленников, и требует затрат на установку и обслуживание физического оборудования.

Данный уровень применим в сценариях, где Edge-устройства слишком ограничены для формирования целостной картины состояния системы, а прямое взаимодействие с облаком невозможно из-за жестких требований к задержке или нестабильности каналов связи.

**Архитектурные паттерны интеграции.** Для построения масштабируемых и надежных IoT-платформ используются различные архитектурные подходы, которые определяют, как компоненты системы взаимодействуют друг с другом.

Управление жизненным циклом моделей в крупных экосистемах обеспечивает MLOps-ориентированная архитектура [6]. Она автоматизирует развертывание, мониторинг качества, переобучение и доставку обновлений на множество устройств.

Расширением централизованной облачной модели является архитектура Edge MLOps, которая частично переносит некоторые возможности облачного MLOps на периферийные устройства.

Для ее реализации критически важны: стандартизация форматов моделей, поддержка OTA-обновлений, контроль данных. Такой подход обеспечивает высокую надежность и устойчивость, что критически важно для крупных распределенных IoT-систем, работающих в реальном времени.

**Федеративное обучение.** Интеграция машинного обучения в архитектуру Интернета вещей — это непрерывный процесс, называемый жизненным циклом ML-модели. В контексте IoT этот цикл имеет свою специфику, обусловленную ограниченными ресурсами периферийных устройств и необходимостью постоянной адаптации к изменяющимся условиям. Актуальным методом обучения является федеративное обучение.

Федеративное обучение является частным случаем распределенного машинного обучения, но его основной акцент смещен с производительности на сохранение приватности и децентрализацию данных. Его ключевая особенность заключается в том, что исходные данные не покидают клиентские устройства [7]. Вместо этого устройства обучают модель на локальных данных и передают на центральный сервер или Fog-узел только обновления весов для формирования глобальной модели. Такой подход значительно снижает сетевую нагрузку и минимизирует риск при передаче данных.

В рамках федеративного обучения применяются различные стратегии агрегации, наиболее распространенными из которых являются усреднение локальных обновлений весов (FedAvg) и метод FedProx, обеспечивающий устойчивость при работе с разнородными данными и устройствами. Выбор алгоритма определяется характером данных, распределением вычислительных мощностей и требованиями к стабильности обучения.

**Заключение.** В совокупности уровни Cloud, Fog и Edge формируют согласованную архитектуру, в которой каждый компонент выполняет строго определенную роль и дополняет остальные. Облачный уровень обеспечивает вычислительную мощность и централизованное управление жизненным циклом систем. Fog-уровень выступает связующим звеном, реализуя горизонтальную оркестрацию, распределенную аналитику и координацию множества Edge-узлов в пределах локальной инфраструктуры. Edge-уровень обеспечивает мгновенный отклик, автономную работу и выполнение вычислений на устройствах. Такое разделение позволяет эффективно использовать ресурсы, обеспечивать конфиденциальность данных и поддерживать устойчивость IoT-систем в условиях динамичных и потенциально нестабильных сред.

Интеграция MLOps-подходов позволяет поддерживать согласованность моделей, автоматизировать обновления и обеспечивать устойчивость работы. Федеративное обучение предоставляет механизмы для непрерывного совершенствования моделей с сохранением конфиденциальности данных. Использование отдельных стратегий обучения позволяет адаптироваться к различиям в данных и вычислительных возможностях устройств.

Такое сочетание многоуровневой архитектуры, распределенного управления моделями и частных методов обучения формирует основу для создания масштабируемых интеллектуальных IoT-систем, способных адаптироваться к динамичным условиям и обеспечивать высокую автономность.

**Список использованных источников:**

1. Папуловская Н. В. Основы интернета вещей : учебно-методическое пособие / Н. В. Папуловская — Екатеринбург: Изд-во Урал. ун-та, 2022. — 104 с.
2. State of IoT 2025: Number of connected IoT devices growing 14% to 21.1 billion globally [Электронный ресурс]. — Электронные данные. — Режим доступа: <https://iot-analytics.com/number-connected-iot-devices> — Дата доступа: 27.03.2026.
3. Kalyashina, A., Smirnov, Y., Esov, V., Kuznetsov, M., & Dmitrieva, O. (2024). Enhancing IoT systems through Cloud-Fog-Edge architectures: challenges and opportunities. *E3S Web of Conferences*, 583, 06012. <https://doi.org/10.1051/e3sconf/202458306012>
4. Kallimani R., Pai K., Raghuwanshi P., Iyer S., López O. L. A. TinyML: Tools, Applications, Challenges, and Future Research Directions [Электронный ресурс] — Режим доступа: <https://arxiv.org/pdf/2303.13569> — Дата доступа: 27.03.2026
5. Gupta H., Bharti A. K. Fog Computing & IoT: Overview, Architecture and Applications // *International Journal of Advanced Research in Computer and Communication Engineering*. 2018. Vol. 7 (5). P. 30—33
6. Kreuzberger D., Kühl N., Hirschl S. Machine Learning Operations (MLOps): Overview, Definition, and Architecture [Электронный ресурс] — Режим доступа: <https://arxiv.org/pdf/2205.02302> — Дата доступа: 27.03.2026
7. Li T., Sahu A. K., Talwalkar A., Smith V. Federated Learning: Challenges, Methods, and Future Directions // *IEEE Signal Processing Magazine*. 2020. Vol. 37, No. 3. P. 50—60.

UDC 004.8:004.7

## THE INTEGRATION OF MACHINE LEARNING INTO IOT ARCHITECTURE

*Slavinsky G.A., master's student*

*Belarusian State University of Informatics and Radioelectronics, Minsk, Republic of Belarus*

*Bobrova N.L. — PhD in Technical Sciences*

**Annotation.** This article describes the computing layers of modern ML-enabled IoT architecture: **Cloud**, **Fog**, and **Edge**. It examines architectural integration patterns using an MLOps-oriented architecture as an example, along with key federated learning strategies. The research findings can be applied to the design of fault-tolerant and scalable intelligent IoT systems.

**Keywords.** Machine learning, Internet of things, Cloud, Fog, Edge, MLOps, federated learning.