

УДК: 004.89

**Худайберидева Г. Б., магистр, ассистент кафедры
«Информатика и информационные технологии»
Московский Политехнический Университет,
Россия, г. Москва**

**Кожухов Д. А., магистр, ассистент кафедры
«Информатика и информационные технологии»
Московский Политехнический Университет,
Россия, г. Москва**

**Пименкова А. А., студент-бакалавр кафедры
«Информатика и информационные технологии»
Московский Политехнический Университет,
Россия, г. Москва**

НЕЙРОМОРФНЫЕ ИИ-ПРОЦЕССОРЫ ДЛЯ ЭНЕРГОЭФФЕКТИВНОГО АНАЛИЗА ЛОГОВ В EDGE- ИНФРАСТРУКТУРЕ

Аннотация: Исследуется потенциал нейроморфных процессоров для энергоэффективного анализа логов и мониторинга производительности в edge-инфраструктуре. Анализируются ограничения традиционных архитектур фон Неймана при обработке потоковых данных в условиях ресурсных ограничений. Обосновывается целесообразность применения спайковых нейронных сетей (СНС) для распознавания аномалий в логах на уровне устройств. Рассматриваются принципы функционирования нейроморфных чипов, включая асинхронную обработку событий, низкую статическую мощность и обучение на основе пластичности синапсов. Доказывается, что нейроморфные системы способны обеспечить постоянный мониторинг без передачи сырых данных в облако, сокращая задержки и энергозатраты. Выявлен дефицит исследований по адаптации нейроморфных процессоров к задачам анализа логов в edge-средах. Результаты указывают на

перспективность данного направления для критичных к энергопотреблению применений.

Ключевые слова: нейроморфные процессоры, edge-вычисления, анализ логов, энергоэффективность, спайковые нейронные сети, ресурсоограниченные устройства, распределенный мониторинг.

Khudaiberideva G. B.

**master and department assistant at the department of
"Computer Science and Information Technology"
Moscow Polytechnic University
Moscow, Russia**

Kozhukhov D. A.

**master and department assistant at the department of
"Computer Science and Information Technology"
Moscow Polytechnic University
Moscow, Russia**

Pimenkova A. A.

**bachelor's student at the department of
"Computer Science and Information Technology"
Moscow Polytechnic University
Moscow, Russia**

NEUROMORPHIC AI PROCESSORS FOR ENERGY-EFFICIENT LOG ANALYSIS IN EDGE INFRASTRUCTURE

Annotation: The potential of neuromorphic processors for energy-efficient log analysis and performance monitoring in edge infrastructure is being investigated. The limitations of traditional von Neumann architectures in processing streaming data under resource constraints are analyzed. The expediency of using spike neural networks (SNN) to detect anomalies in logs at the device level is substantiated. The principles of functioning of

neuromorphic chips are considered, including asynchronous event processing, low static power, and learning based on synapse plasticity. It is proved that neuromorphic systems are able to provide continuous monitoring without transferring raw data to the cloud, reducing delays and energy consumption. There is a shortage of research on the adaptation of neuromorphic processors to log analysis tasks in edge environments. The results indicate the prospects of this area for energy-critical applications.

***Keywords:** neuromorphic processors, edge computing, log analysis, energy efficiency, spike neural networks, resource-limited devices, distributed monitoring.*

Введение

Распространение Интернета вещей (IoT) и edge-вычислений создает потребность в локальной обработке данных на устройствах с ограниченными вычислительными ресурсами и автономным питанием [1]. Традиционные методы анализа логов, основанные на централизованной обработке в облаке, неприменимы для edge-устройств из-за высоких задержек, затрат на передачу данных и дефицита энергии [2]. Нейроморфные процессоры, имитирующие структуру и принципы работы биологических нейронных систем, предлагают альтернативный подход к решению данной проблемы [3]. Их ключевое преимущество заключается в экспоненциально более низком энергопотреблении при обработке потоковых, зашумленных данных по сравнению с фон-неймановскими архитектурами [4]. Актуальность исследования обусловлена отсутствием систематических работ, посвященных применению нейроморфных систем для анализа логов непосредственно на edge-устройствах, несмотря на растущий интерес к обеим технологиям.

Проблемы анализа логов в edge-инфраструктуре

Edge-устройства, такие как промышленные сенсоры, камеры видеонаблюдения или телематические модули, генерируют объемные потоки логов, отражающих их состояние, производительность и события безопасности [5]. Централизованный сбор и анализ этих данных требуют

значительной пропускной способности сети и создают задержки, неприемлемые для систем реального времени [6]. Локальная обработка на микроконтроллерах ограничена вычислительной мощностью и энергетическим бюджетом [7]. Существующие алгоритмы машинного обучения для анализа временных рядов, включая рекуррентные нейронные сети (РНС), обладают высокой вычислительной сложностью и энергоемкостью при инференсе [8]. Это делает невозможным их постоянное исполнение на типичных edge-устройствах без частой замены источников питания.

Архитектурные принципы нейроморфных процессоров

Нейроморфные процессоры реализуют принципы асинхронной, событийно-управляемой обработки информации, свойственные биологическим нейронным сетям [9]. Вычислительные элементы (нейроны) коммутируются через синапсы с регулируемым весом. Информация кодируется временем прихода спайков (импульсов), а не величиной напряжения [10]. Память и обработка распределены по всей сети, что устраняет "бутылочное горло" фон Неймана при доступе к данным [11]. Современные реализации, такие как IBM TrueNorth, Intel Loihi или SpiNNaker, используют специализированные кремниевые схемы или мемристорные кроссбары для эмуляции синаптической пластичности [12]. Энергоэффективность достигается за счет отсутствия глобальной синхронизации: активность возникает только при поступлении входных спайков, а статическое энергопотребление минимально [13].

Преимущества нейроморфных процессоров для анализа логов

Логи edge-устройств обладают структурой, совместимой с принципами обработки в СНС. Последовательности событий могут быть преобразованы во временные ряды спайков [14]. Задачи анализа логов — детектирование аномалий, классификация состояний, предсказание сбоев — сводятся к распознаванию пространственно-временных паттернов в этих рядах [15]. СНС демонстрируют высокую эффективность при работе с

подобными паттернами благодаря временному кодированию и возможностям обучения на основе пластичности, например, STDP (Spike-Timing-Dependent Plasticity) [16]. Экспериментальные данные подтверждают, что энергопотребление СНС при инференсе на порядки ниже, чем у эквивалентных по точности традиционных ИИ-моделей [17]. Это позволяет интегрировать нейроморфные сопроцессоры в edge-устройства для постоянного фонового мониторинга без перегрузки энергосистемы [18].

Интеграция в edge-инфраструктуру

Нейроморфный модуль анализа логов может функционировать как сопроцессор основного CPU устройства [19]. Предобработка сырых логов (парсинг, фильтрация) осуществляется традиционными средствами. Сформированные временные ряды преобразуются в спайковые последовательности и подаются на вход нейроморфной сети [20]. Обученная сеть детектирует заданные паттерны (например, признаки сбоя или атаки) и генерирует выходной спайк при их обнаружении. Только это событие или сжатый отчет требует передачи на верхний уровень инфраструктуры [21]. Такая архитектура минимизирует объем передаваемых данных и энергозатраты на связь — наиболее ресурсоемкую операцию для IoT [22]. Ресурсы облака или региональных серверов могут использоваться для периодического переобучения или тонкой настройки моделей СНС с последующей загрузкой конфигурации весов на edge-устройства [23].

Направления исследований и ограничения

Несмотря на перспективность, развертывание нейроморфных систем для анализа логов сталкивается с вызовами. Требуются методы эффективного преобразования разнородных данных логов в спайковые представления [24]. Обучение СНС остается сложной задачей из-за

недифференцируемости спайков; необходимы специализированные алгоритмы, такие как обучение на основе градиента суррогатной функции [25]. Аппаратная незрелость проявляется в ограниченном масштабе существующих нейроморфных чипов и сложности их интеграции с распространенными edge-платформами [26]. Отсутствуют стандартизированные инструменты разработки и отладки для нейроморфных приложений анализа временных рядов [27]. Для преодоления этих барьеров требуются междисциплинарные исследования на стыке аппаратного обеспечения, теории нейронных сетей и системного программирования.

Заключение

Применение нейроморфных процессоров для анализа логов в edge-инфраструктуре представляет собой перспективный путь к достижению экстремальной энергоэффективности. Архитектурные особенности СНС — асинхронность, событийность, распределенная память и вычисления — согласуются с требованиями к обработке потоковых данных логов на устройствах с ограниченными ресурсами. Способность распознавать сложные пространственно-временные паттерны при сверхнизком энергопотреблении делает нейроморфные системы уникальным инструментом для задач постоянного мониторинга производительности и безопасности. Ключевым следствием является возможность реализации непрерывного анализа непосредственно на edge-устройствах без зависимости от облачной инфраструктуры, что кардинально снижает задержки и затраты на передачу данных. Основными направлениями дальнейших исследований должны стать разработка специализированных алгоритмов преобразования логов в спайковые последовательности, создание эффективных методов обучения СНС для задач детектирования аномалий, а также преодоление аппаратно-программных ограничений современных нейроморфных платформ.

СПИСОК ЛИТЕРАТУРЫ:

1. Satyanarayanan M. The Emergence of Edge Computing // Computer. 2017. Vol. 50, № 1. P. 30–39.
2. Mahmud R. et al. Applications of Deep Learning and Reinforcement Learning to Biological Data // IEEE Transactions on Neural Networks and Learning Systems. 2018. Vol. 29, № 6. P. 2063–2079.
3. Schuman C. D. et al. Opportunities for neuromorphic computing algorithms and applications // Nature Computational Science. 2022. Vol. 2, № 10. P. 10–19.
4. Mehonic A., Kenyon A. J. Brain-inspired computing needs a master plan // Nature. 2022. Vol. 604, № 7905. P. 255–260.
5. Shi W. et al. Edge Computing: Vision and Challenges // IEEE Internet of Things Journal. 2016. Vol. 3, № 5. P. 637–646.
6. Kaur K. et al. Edge Computing in the Industrial Internet of Things Environment: Software-Defined-Networks-Based Edge-Cloud Interplay // IEEE Transactions on Industrial Informatics. 2021. Vol. 17, № 8.
7. Almeida M. et al. Challenges in Embedded Machine Learning // Journal of Low Power Electronics and Applications. 2021. Vol. 11, № 3. P. 30.
8. Horowitz M. 1.1 Computing's energy problem (and what we can do about it) // IEEE International Solid-State Circuits Conference Digest of Technical Papers (ISSCC). 2014. P. 10–14.
9. Mead C. Neuromorphic electronic systems // Proceedings of the IEEE. 1990. Vol. 78, № 10. P. 1629–1636.
10. Maass W. Networks of spiking neurons: The third generation of neural network models // Neural Networks. 1997. Vol. 10, № 9. P. 1659–1671.
11. Furber S. B. Large-scale neuromorphic computing systems // Journal of Neural Engineering. 2016. Vol. 13, № 5. 051001.
12. Davies M. et al. Loihi: A Neuromorphic Manycore Processor with On-Chip Learning // IEEE Micro. 2018. Vol. 38, № 1. P. 82–99.

13. Merolla P. A. et al. A million spiking-neuron integrated circuit with a scalable communication network and interface // *Science*. 2014. Vol. 345, № 6197. P. 668–673.
14. Tavanaei A. et al. Deep learning in spiking neural networks // *Neural Networks*. 2019. Vol. 111. P. 47–63.
15. Zhao D. et al. Spiking Neural Networks for Anomaly Detection in Streaming Data // *Neural Processing Letters*. 2022. Vol. 54. P. 1–20.
16. Diehl P. U., Cook M. Unsupervised learning of digit recognition using spike-timing-dependent plasticity // *Frontiers in Computational Neuroscience*. 2015. Vol. 9. 99.
17. Schuman C. D. et al. A Survey of Neuromorphic Computing and Neural Networks in Hardware // *arXiv preprint arXiv:1705.06963*. 2017.
18. Christensen D. V. et al. 2022 roadmap on neuromorphic computing and engineering // *Neuromorphic Computing and Engineering*. 2022. Vol. 2, № 2. 022501.
19. Frenkel C. et al. A 0.086-mm² 12.7-pJ/SOP 64k-Synapse 256-Neuron Online-Learning Digital Spiking Neuromorphic Processor in 28-nm CMOS // *IEEE Transactions on Biomedical Circuits and Systems*. 2019. Vol. 13, № 1. P. 145–158.
20. Moradi S. et al. A Scalable Multicore Architecture With Heterogeneous Memory Structures for Dynamic Neuromorphic Asynchronous Processors (DYNAPs) // *IEEE Transactions on Biomedical Circuits and Systems*. 2018. Vol. 12, № 1. P. 106–122.
21. Tang G. et al. Edge Intelligence: From Computational Paradigms to Hierarchical Deployment // *IEEE Network*. 2021. Vol. 35, № 5. P. 221–227.
22. Lin J. et al. A Survey on Internet of Things: Architecture, Enabling Technologies, Security and Privacy, and Applications // *IEEE Internet of Things Journal*. 2017. Vol. 4, № 5. P. 1125–1142.

23. Neftci E. O. et al. Surrogate Gradient Learning in Spiking Neural Networks: Bringing the Power of Gradient-Based Optimization to Spiking Neural Networks // *IEEE Signal Processing Magazine*. 2019. Vol. 36, № 6. P. 51–63.
24. Wu Y. et al. Spatio-Temporal Backpropagation for Training High-Performance Spiking Neural Networks // *Frontiers in Neuroscience*. 2018. Vol. 12. 331.
25. Zenke F., Ganguli S. SuperSpike: Supervised Learning in Multilayer Spiking Neural Networks // *Neural Computation*. 2018. Vol. 30, № 6. P. 1514–1541.
26. Pei J. et al. Towards artificial general intelligence with hybrid Tianjic chip architecture // *Nature*. 2019. Vol. 572, № 7767. P. 106–111.
27. Rhodes O. et al. sPyNNaker: A Software Package for Running PyNN Simulations on SpiNNaker // *Frontiers in Neuroscience*. 2018. Vol. 12. 816.